

# 基礎から始める機械学習・深層学習

MathWorks® Japan

アプリケーションエンジニア

井原 瑞希

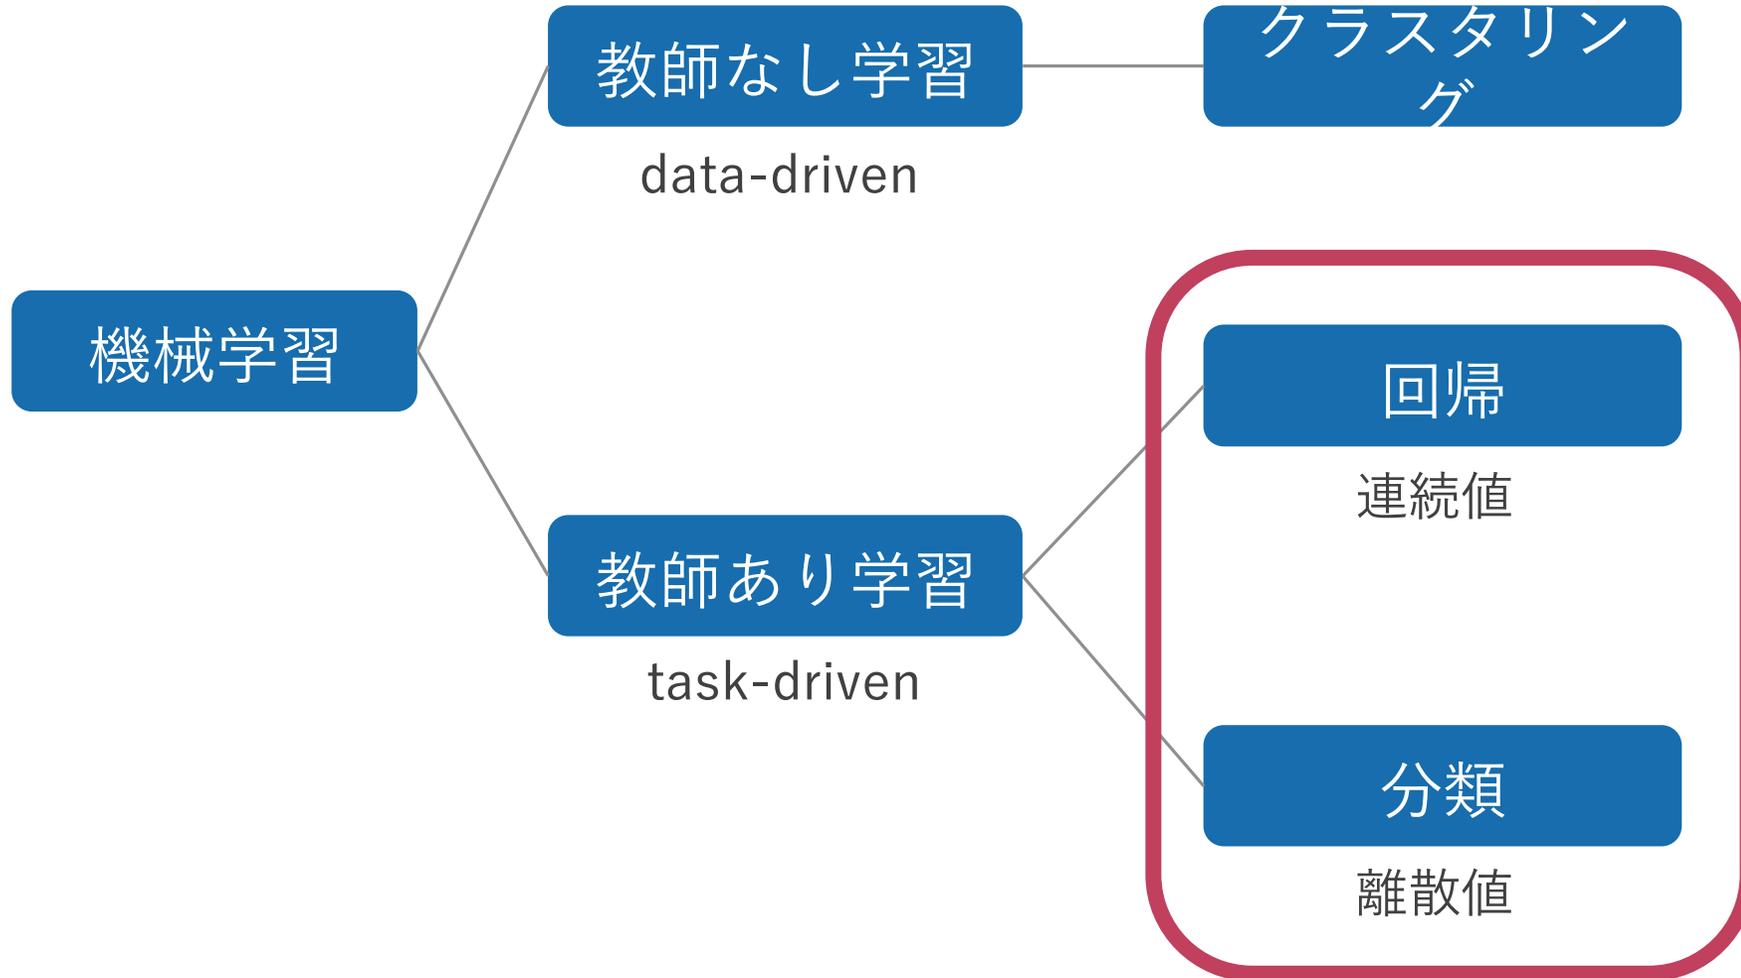
# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の数値の分類
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の信号データの異常検出
  - オートエンコーダ
- Case4: 画像データの分類と異常検出
  - CNN と 転移学習
  - 他のアルゴリズム

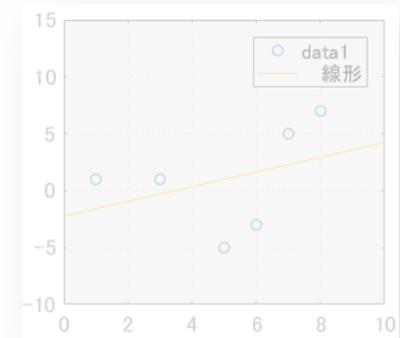
# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の数値の分類
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の信号データの異常検出
  - オートエンコーダ
- Case4: 画像データの分類と異常検出
  - CNN と 転移学習
  - 他のアルゴリズム

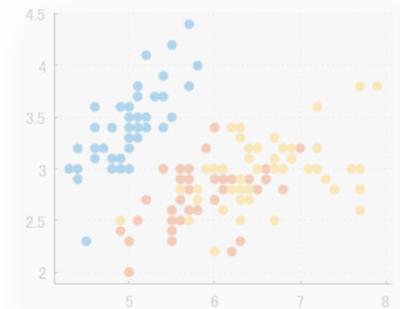
# 機械学習とは



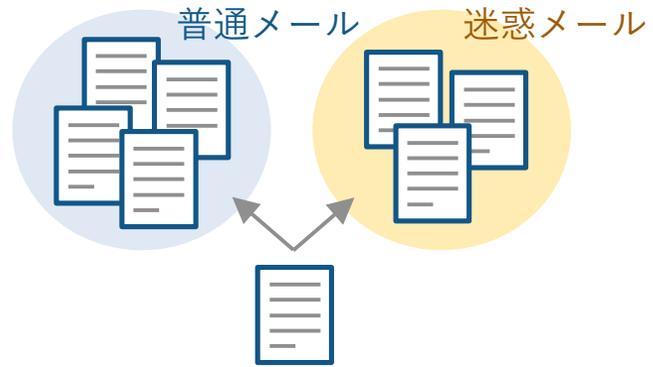
70.5



良 / 可 / 不可



# 分類・認識のタスク



テキスト分類



画像認識



音声認識、センサー分類

# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の**数値**の**分類**
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の**信号****分類**
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の**信号**データの**異常検出**
  - オートエンコーダ
- Case4: **画像**データの**分類**と**異常検出**
  - CNN と 転移学習
  - 他のアルゴリズム

数値

時系列 / 信号  
/ テキスト

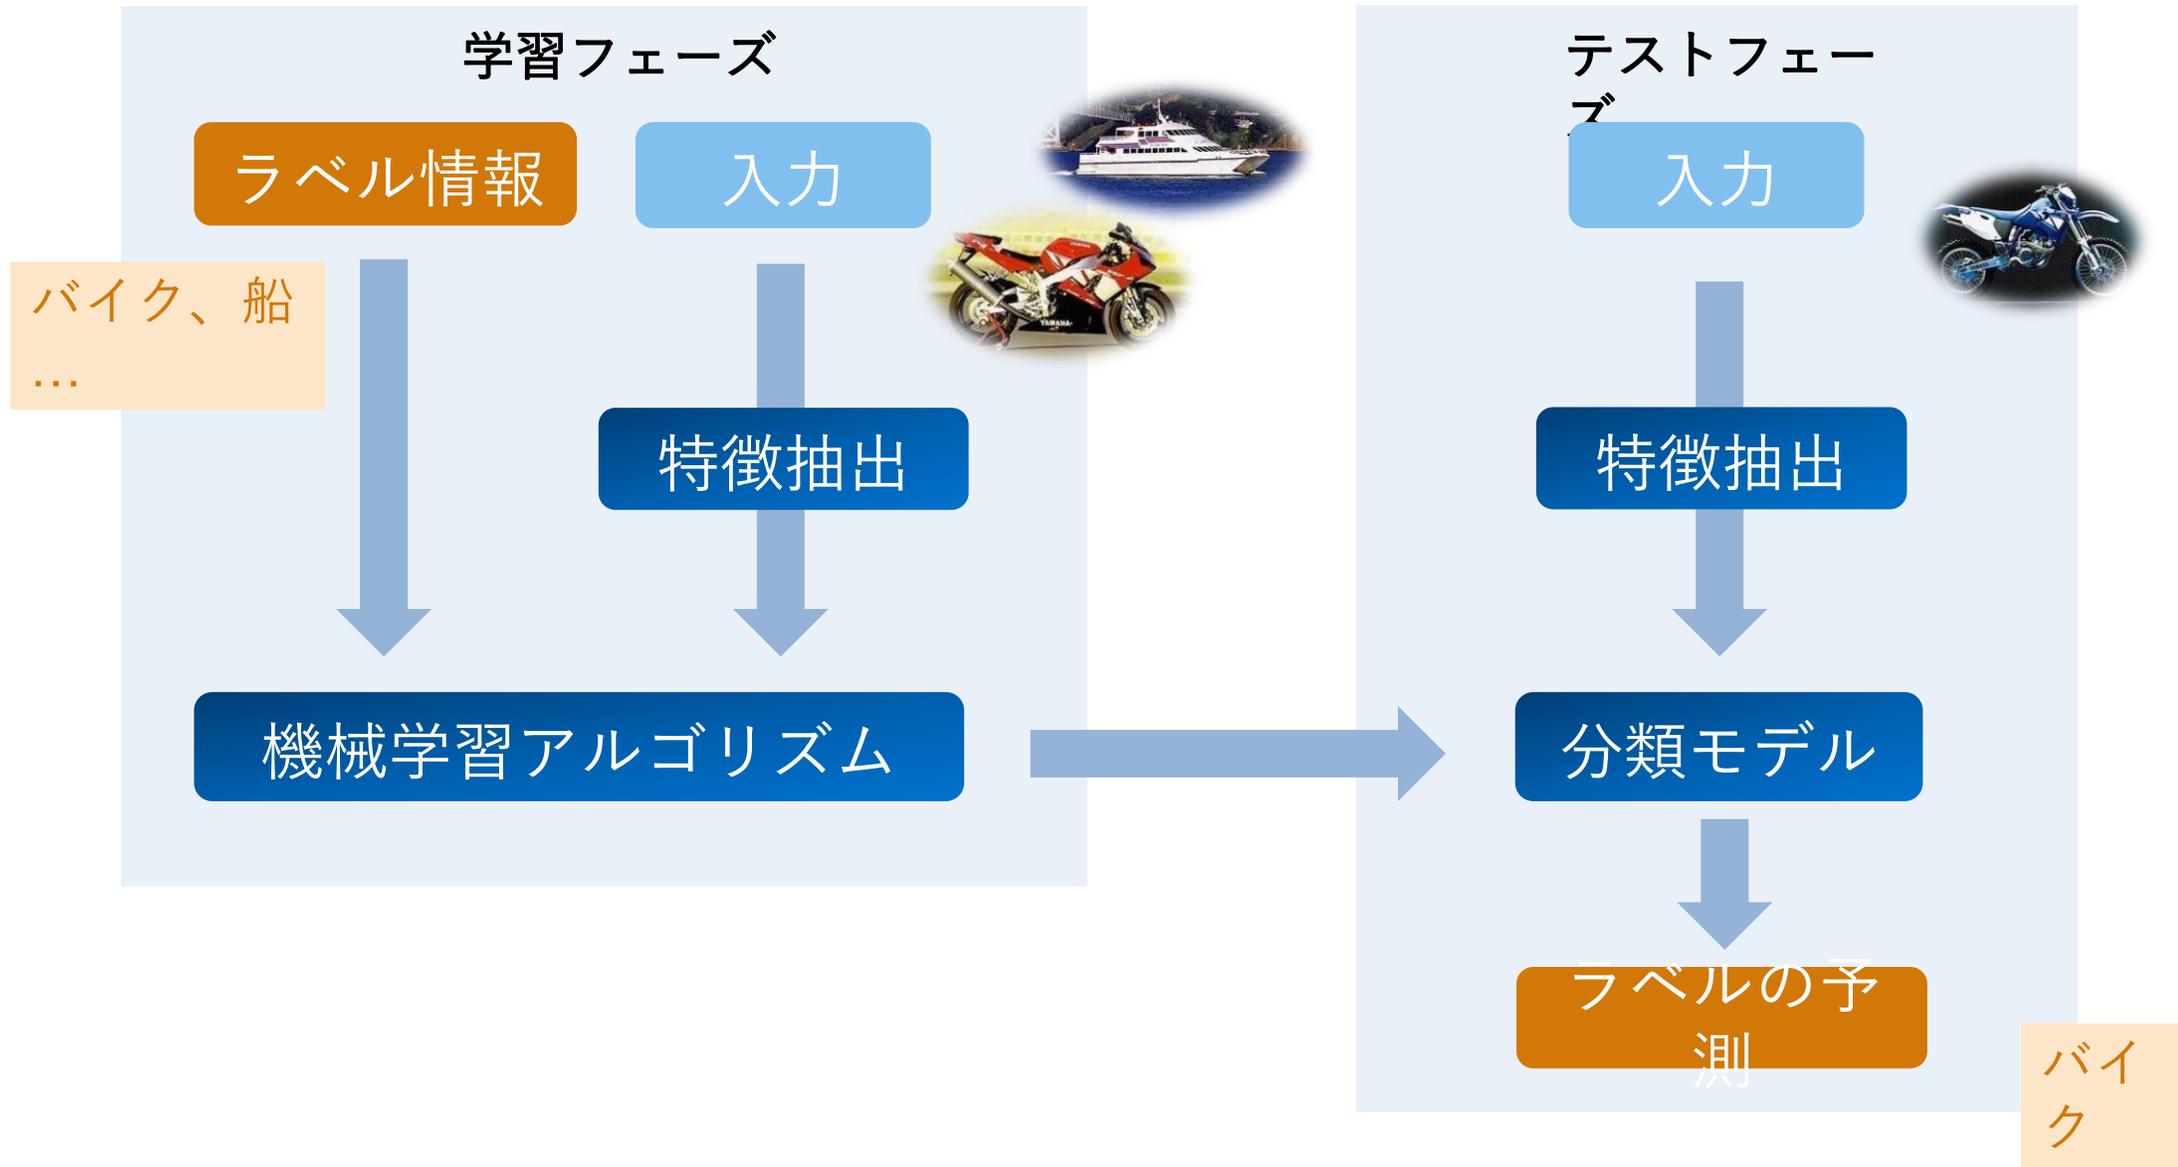
画像

対象となるデータ  
アプリケーション  
アルゴリズム

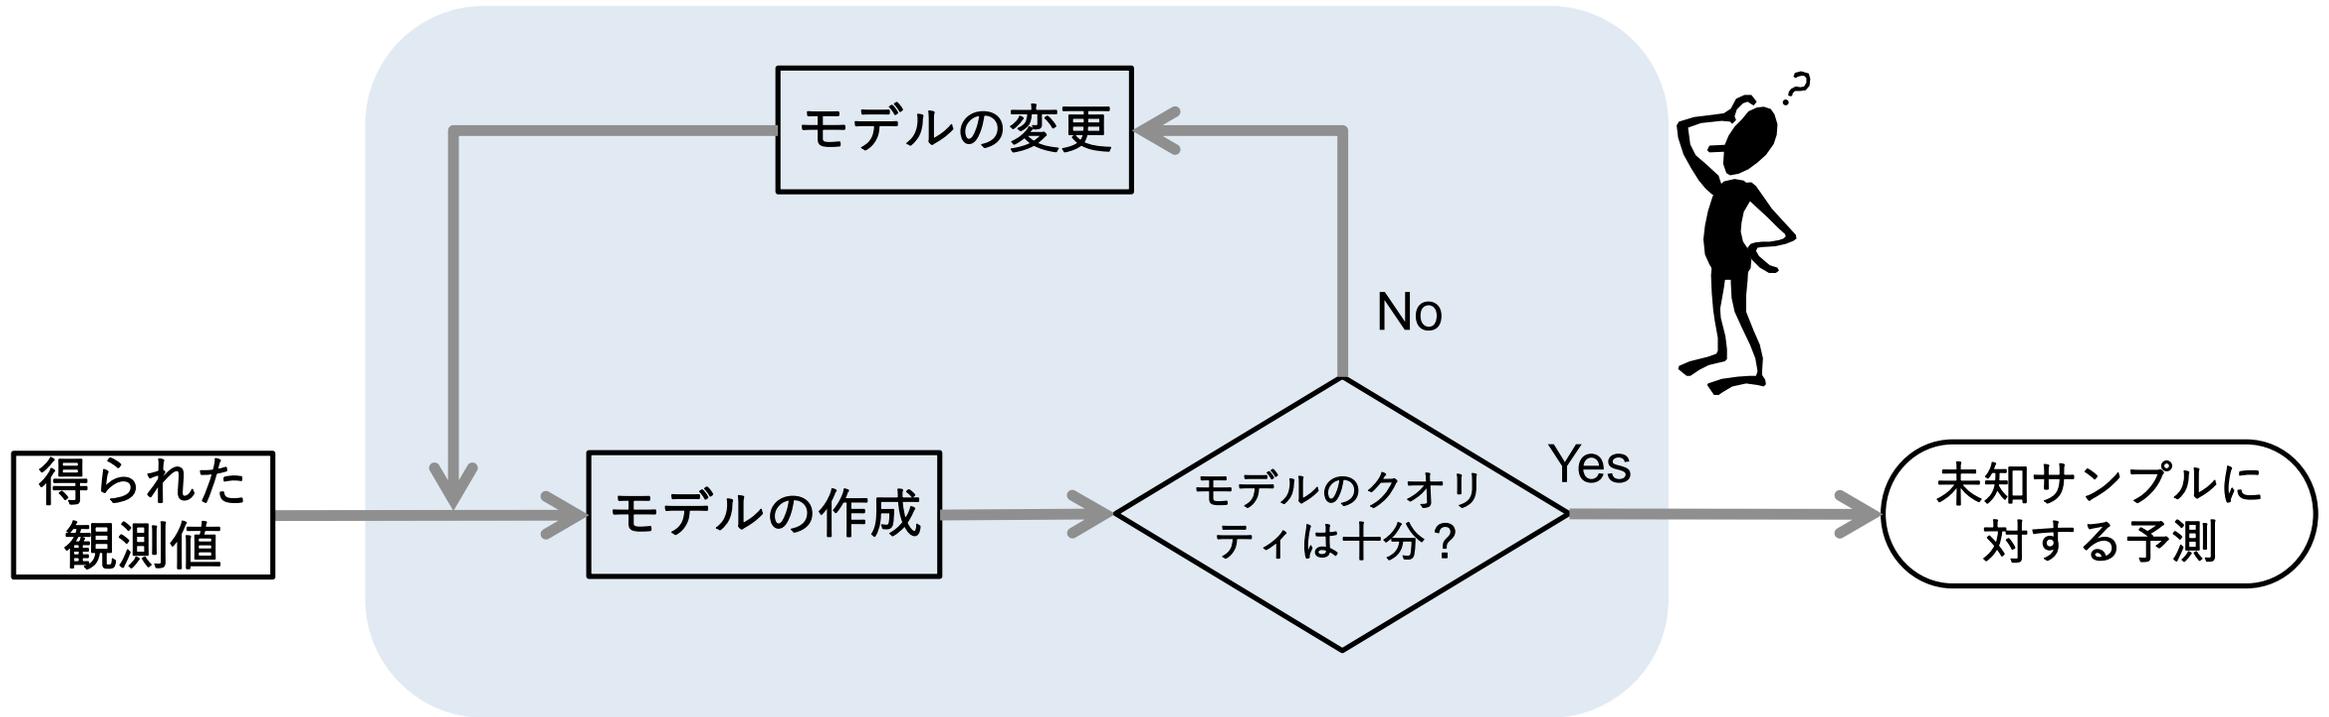
# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の**数値**の**分類**
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の信号データの異常検出
  - オートエンコーダ
- Case4: 画像データの分類と異常検出
  - CNN と 転移学習
  - 他のアルゴリズム

# 分類の流れ



# 分類モデルの作成フロー

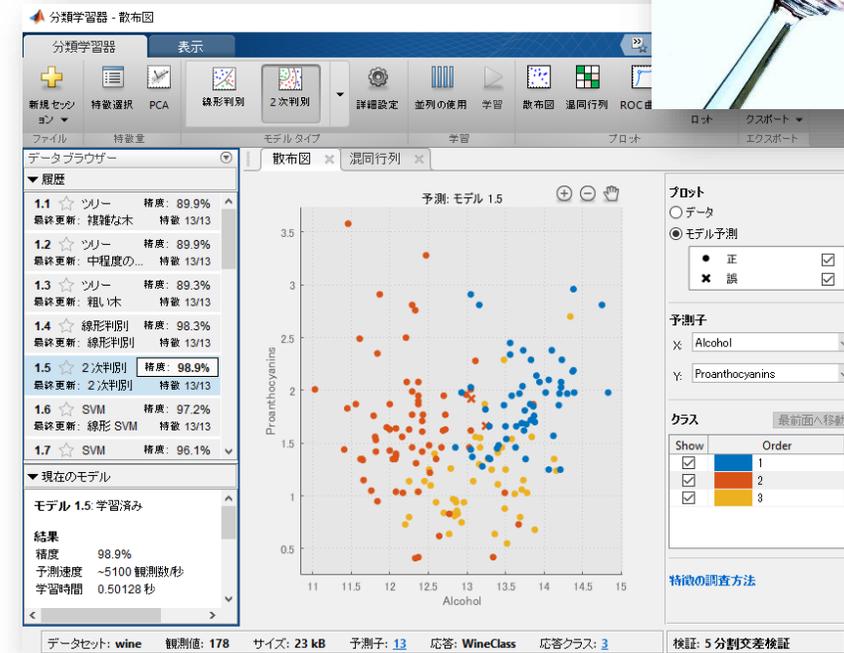


# 例1: 成分からワインの種類を判別

- ワインに含まれる成分からワインの種類を判別
  - 特徴量: リンゴ酸、アルコール、色など
  - 判別対象物: ワイン3種類

## ■ 課題

- どの機械学習手法を使用すべきか
- 機械学習手法のハイパーパラメタはどう設定するか



UCI Machine Learning Repository – Wine Data Set

<https://archive.ics.uci.edu/ml/datasets/wine>

機械学習で分類をする手法/アルゴリズムがたくさんありますが、どれを選べば良いのでしょうか？

<https://jp.mathworks.com/matlabcentral/answers/315669>

R2015a

R2017a



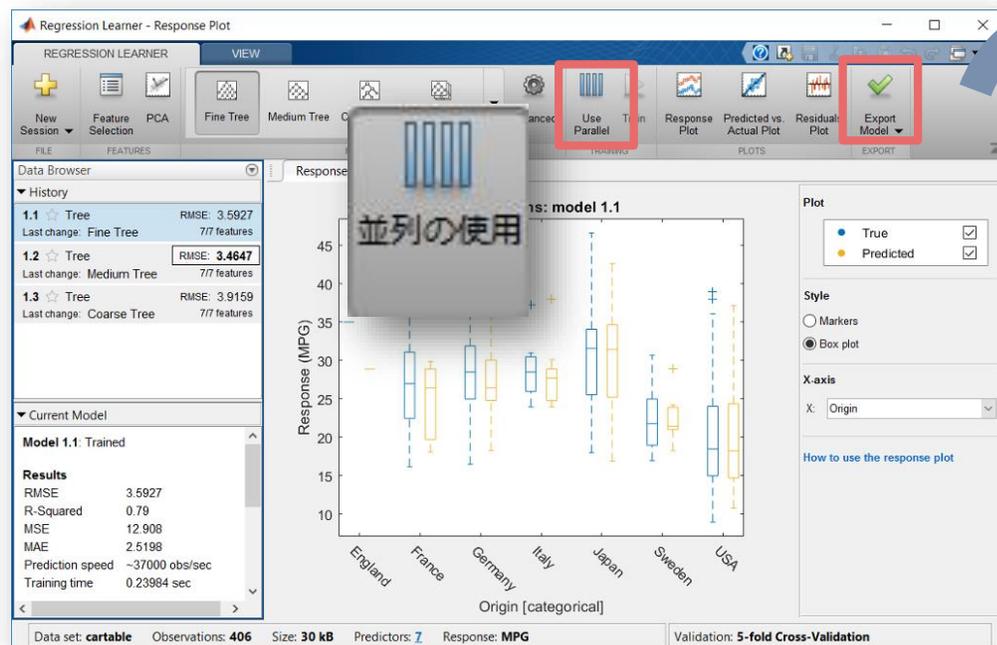
分類学習器



回帰学習器

# アプリから機械学習の MATLAB® コード作成

- 分類/回帰学習器アプリ
  - データを分類するためのモデル学習 GUI
  - GUI 操作を MATLAB コードとして生成可能
  - 複数モデルを並列に学習可能



```

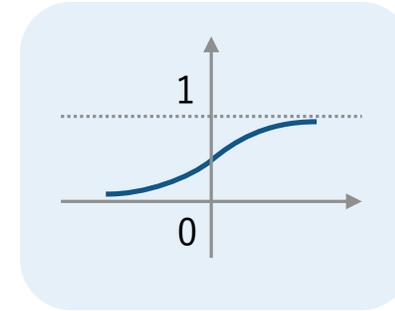
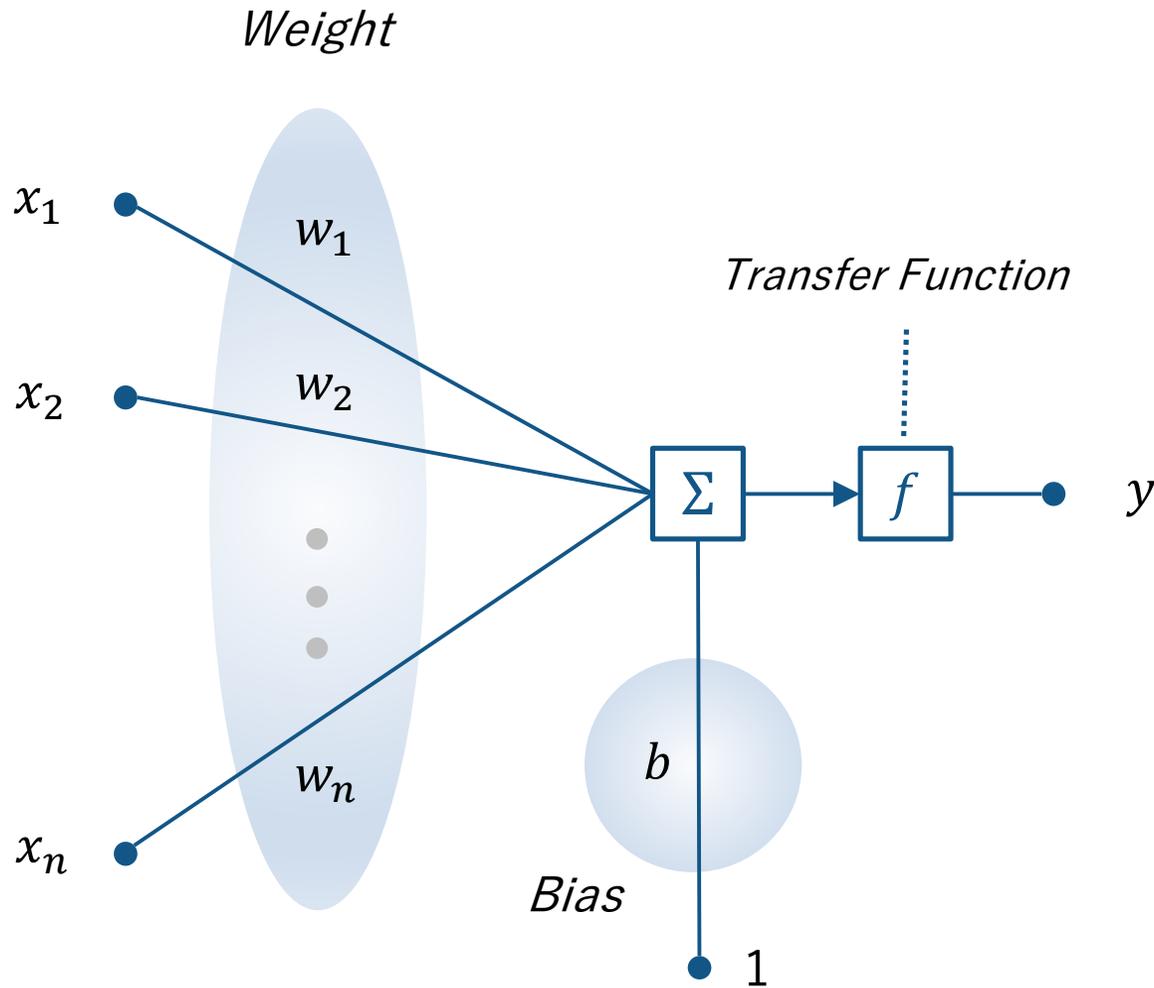
52
53 % 分類器の学習
54 % このコードは、すべての分類器オプションを指定し、分類器に
classificationKNN = fitknn(...
55 predictors, ...
56 response, ...
57 'Distance', 'Euclidean', ...
58 'Exponent', [], ...
59 'NumNeighbors', 1, ...
60 'DistanceWeight', 'Equal', ...
61 'Standardize', true, ...
62 'ClassNames', categorical({'urgent'; 'short'; 'medium'; 'lo
63
64
65 % 関数 predict で結果の構造体を作成
  
```

MATLAB プログラムの自動生成

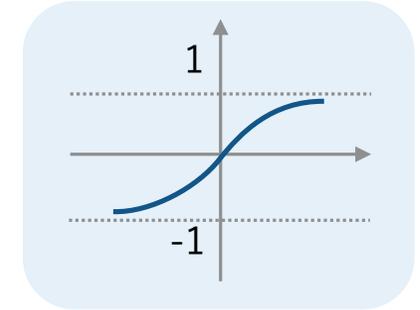
# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- **Case1: 特徴が明確な場合の数値の分類**
  - ニューラルネットワーク以外の機械学習
- **Case2: 特徴が不明瞭な場合の信号分類**
  - ニューラルネットワーク
- **Case3: 特徴が不明瞭な場合の信号データの異常検出**
  - オートエンコーダ
- **Case4: 画像データの分類と異常検出**
  - CNN と 転移学習
  - 他のアルゴリズム

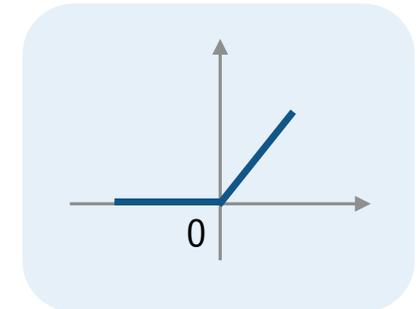
# ニューラルネットワークとは



Logistic Sigmoid



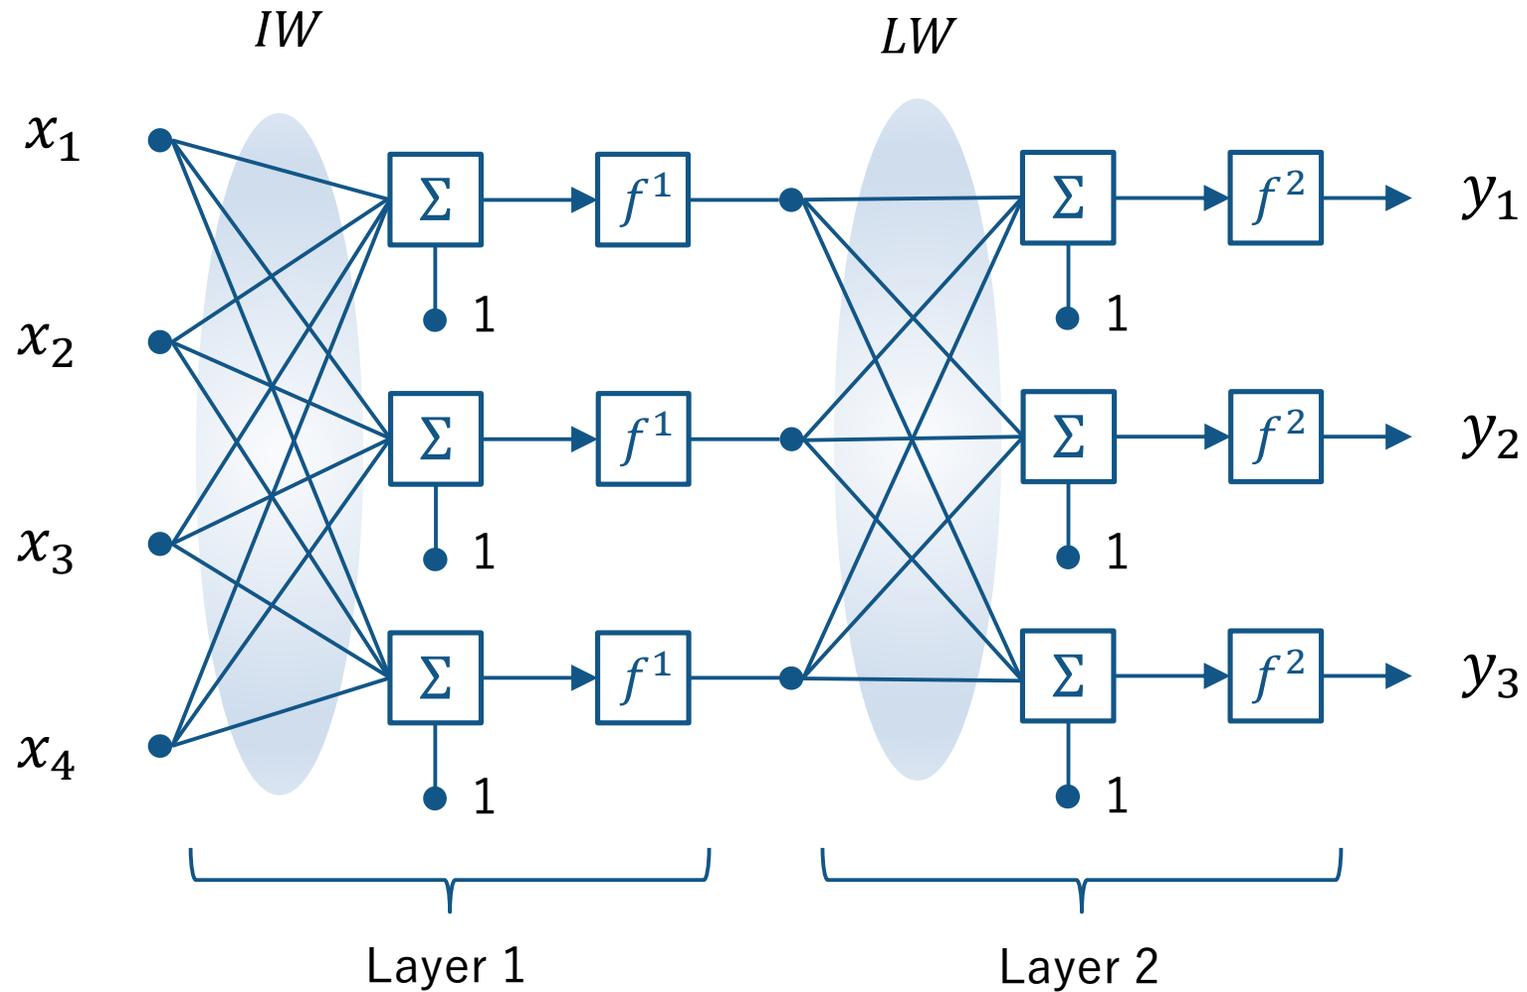
Tangent Sigmoid



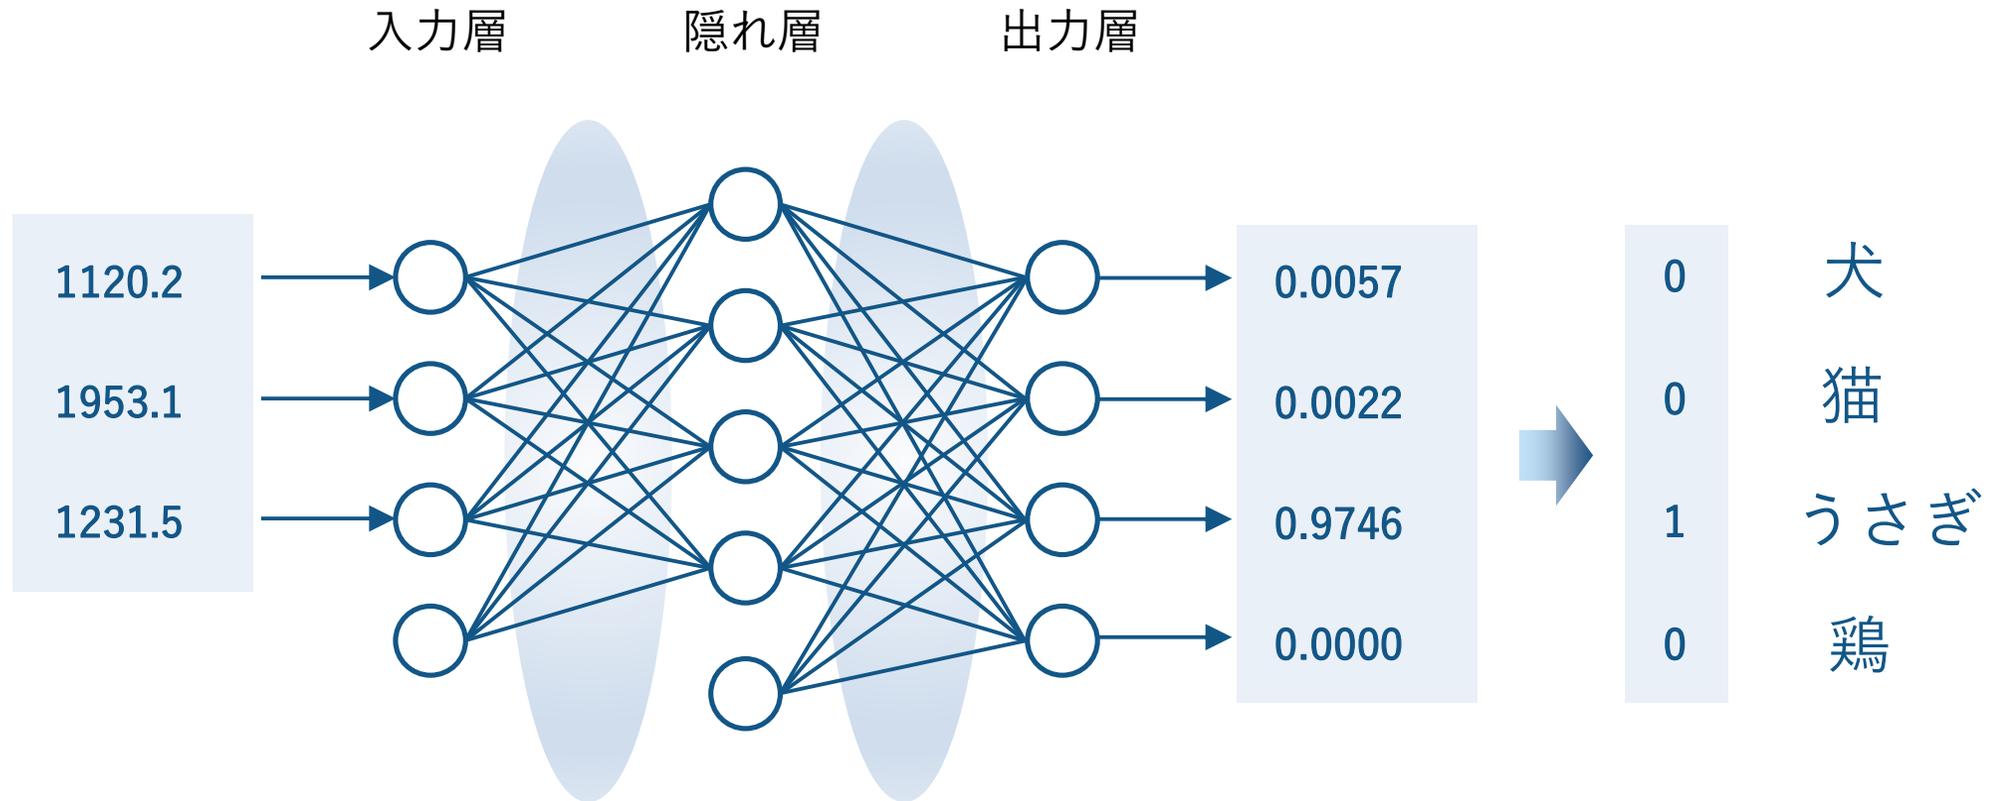
Rectified Linear Unit

$$y = f \left( \sum_{k=1}^n w_k \cdot x_k + b \right)$$

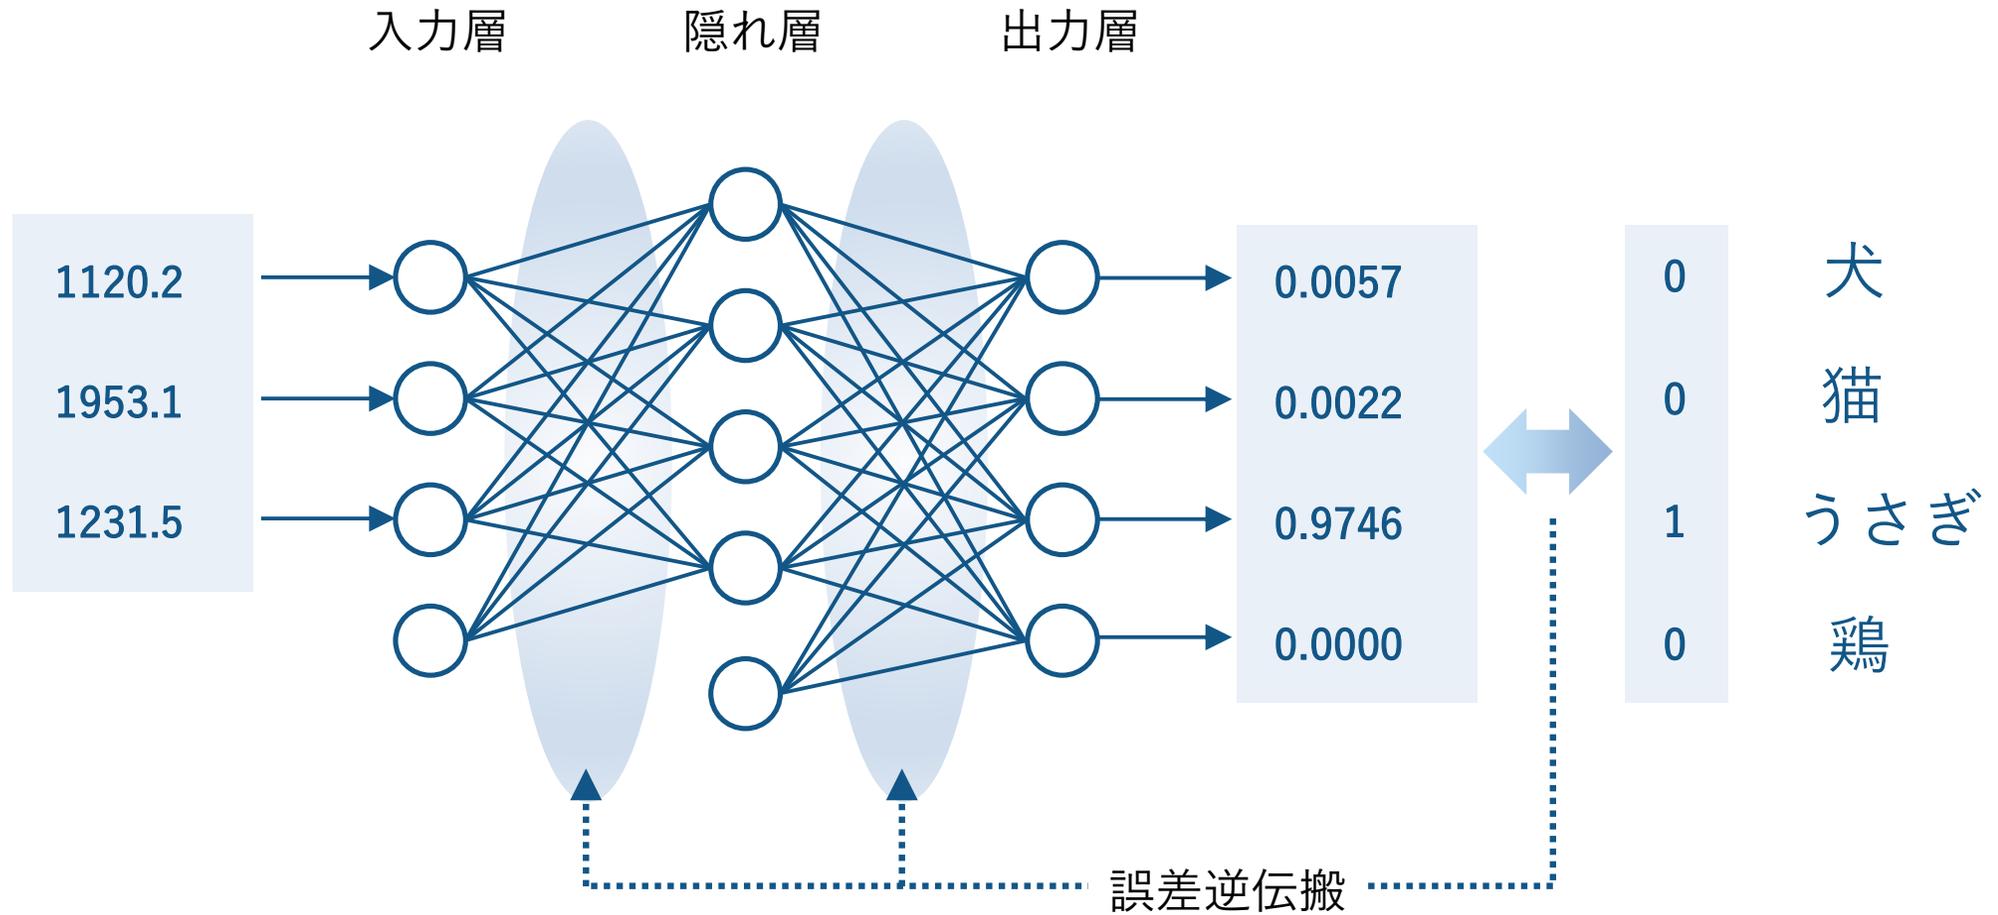
# ニューラルネットワークとは



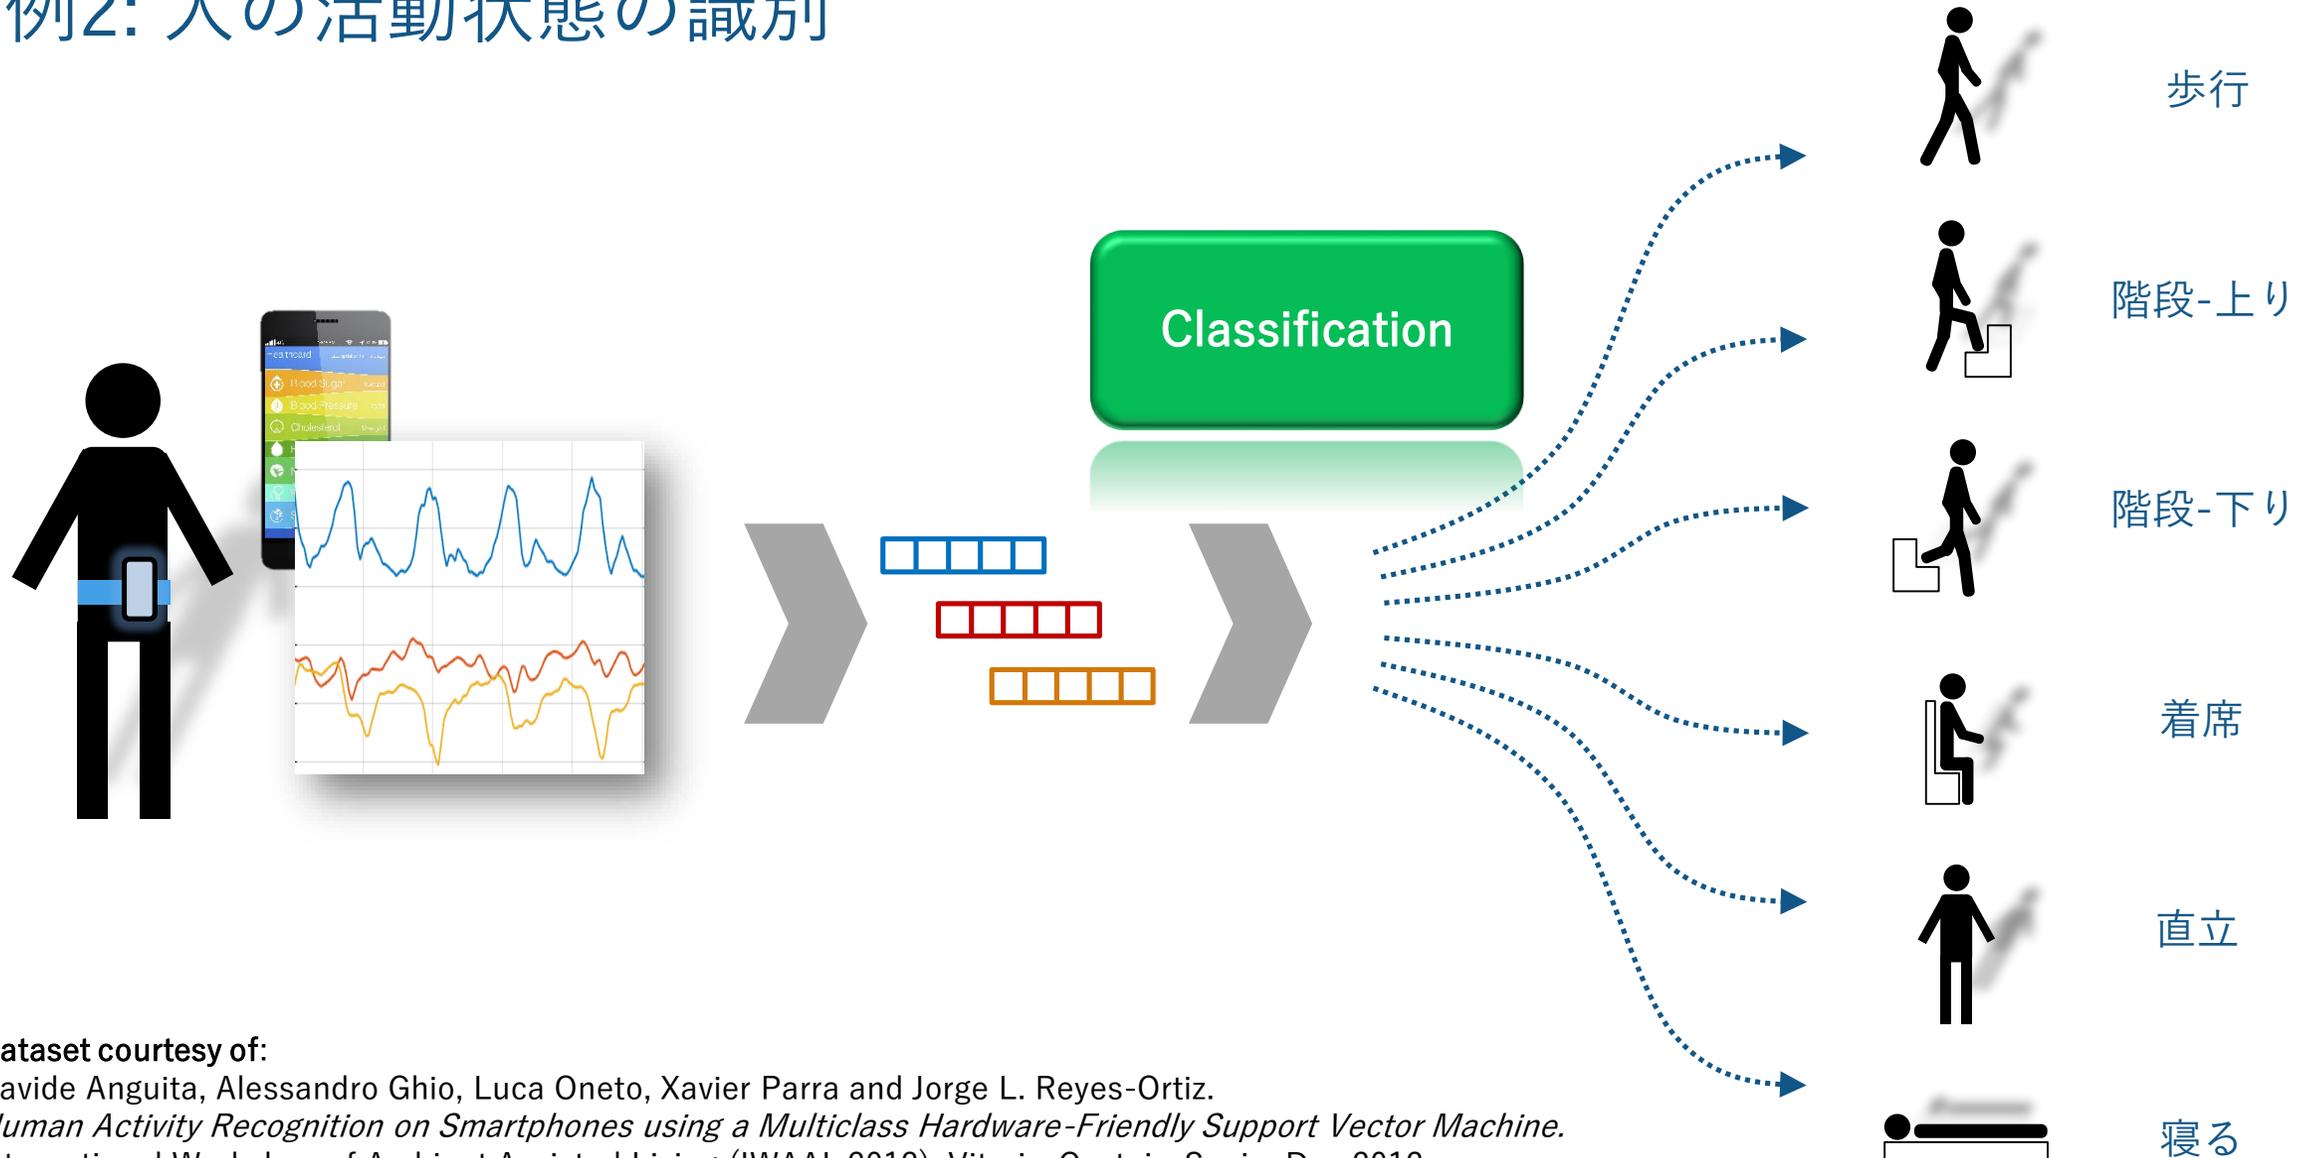
# ニューラルネットワークによる予測



# ニューラルネットワークの学習



## 例2: 人の活動状態の識別



### Dataset courtesy of:

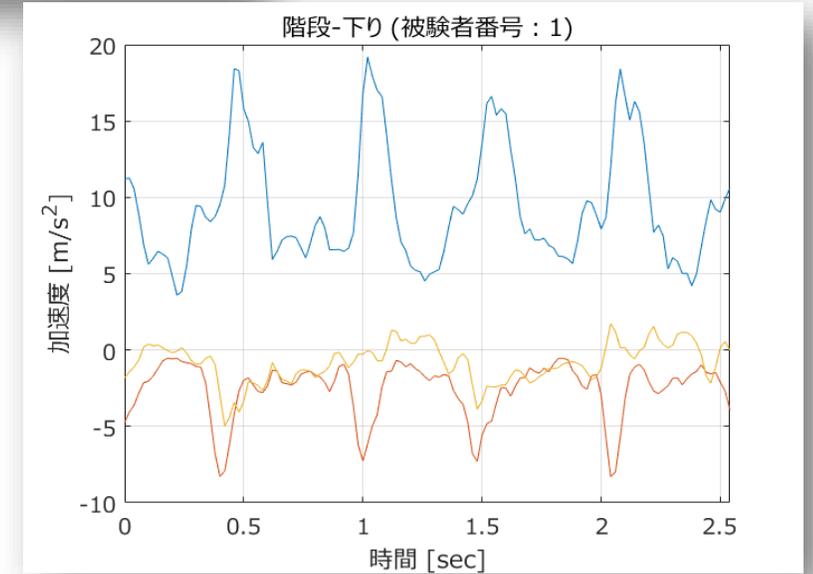
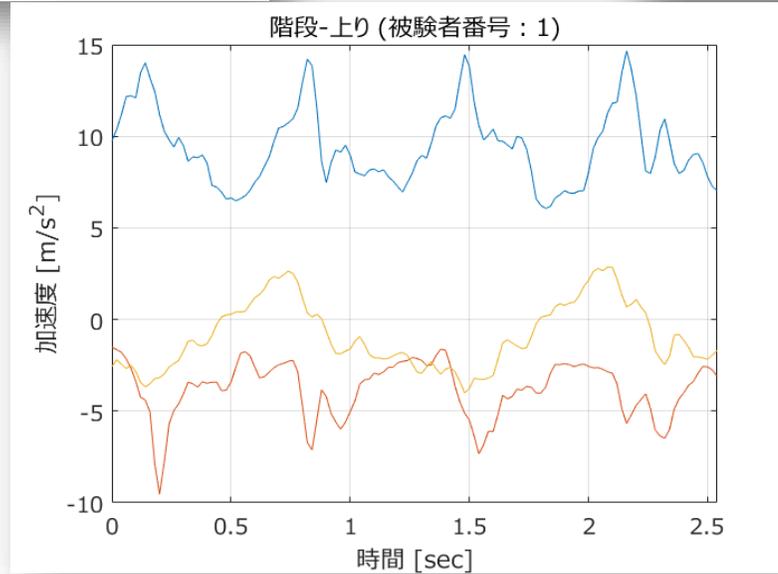
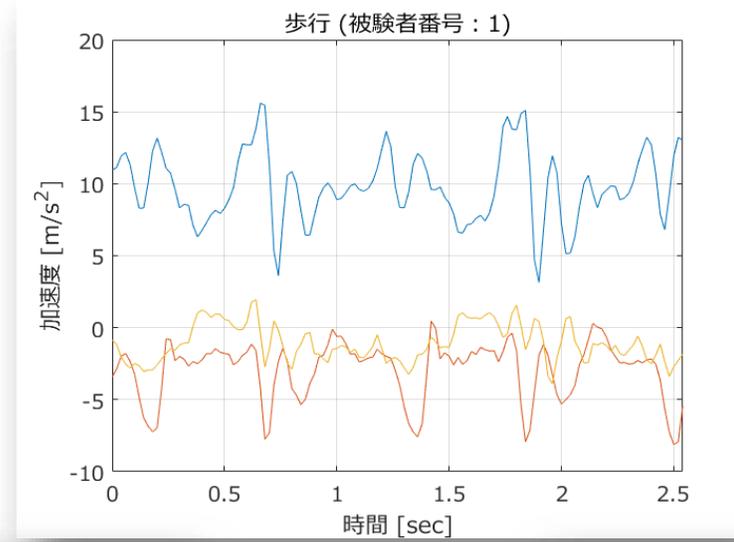
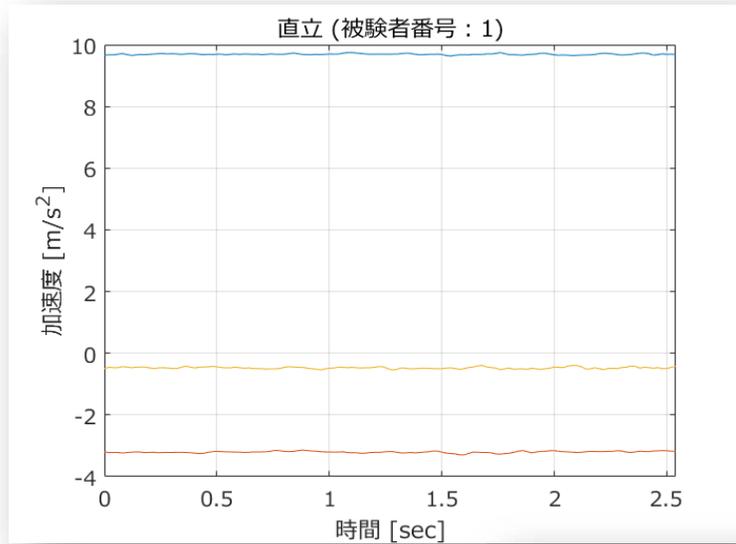
Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra and Jorge L. Reyes-Ortiz.

*Human Activity Recognition on Smartphones using a Multiclass Hardware-Friendly Support Vector Machine.*

International Workshop of Ambient Assisted Living (IWAAL 2012). Vitoria-Gasteiz, Spain. Dec 2012

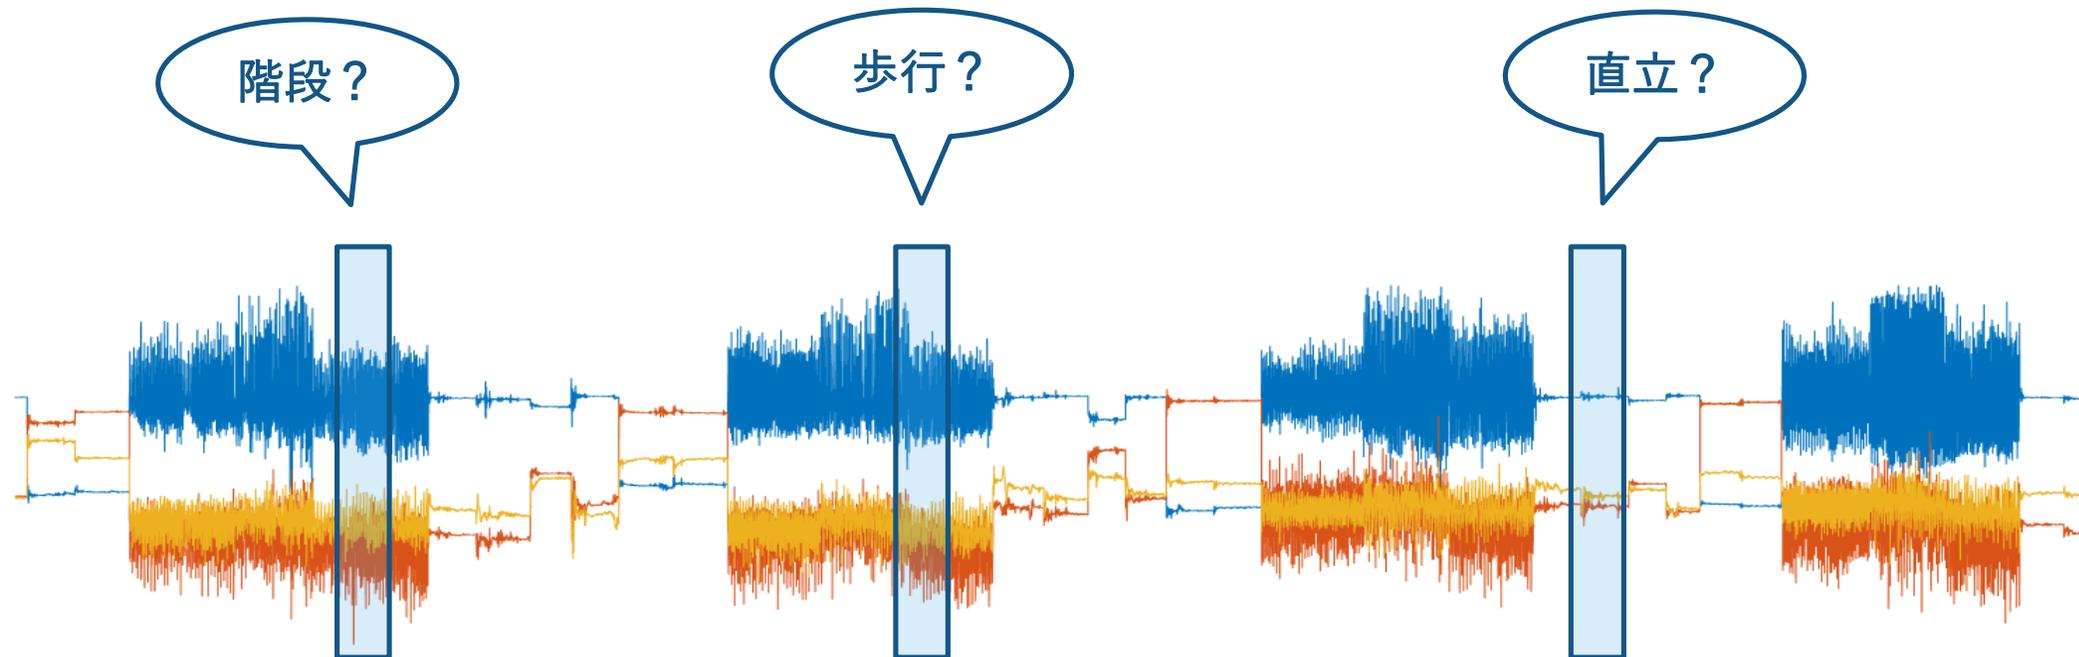
<http://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones>

## 例2: 人の活動状態の識別



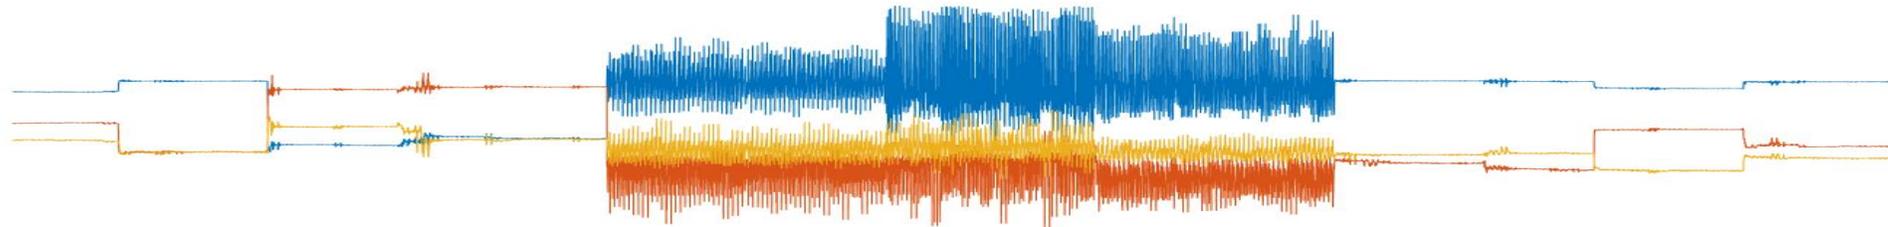
## 例2: 人の活動状態の識別

- 3軸の加速度センサーの情報から人の活動状態を識別

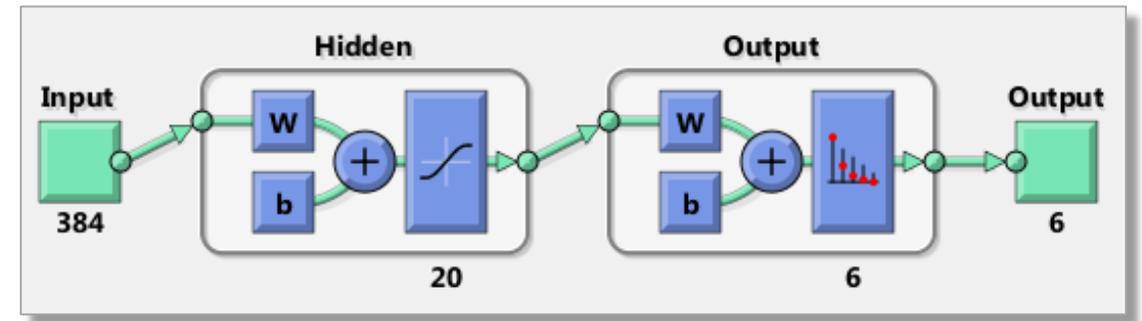
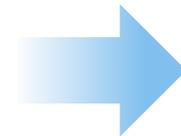
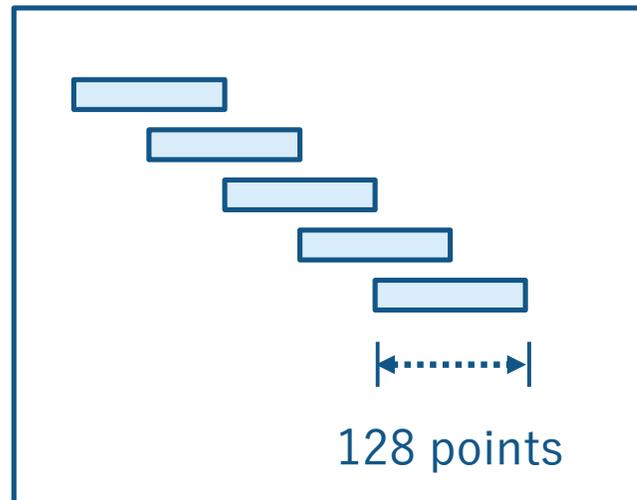


## 例2: 人の活動状態の識別

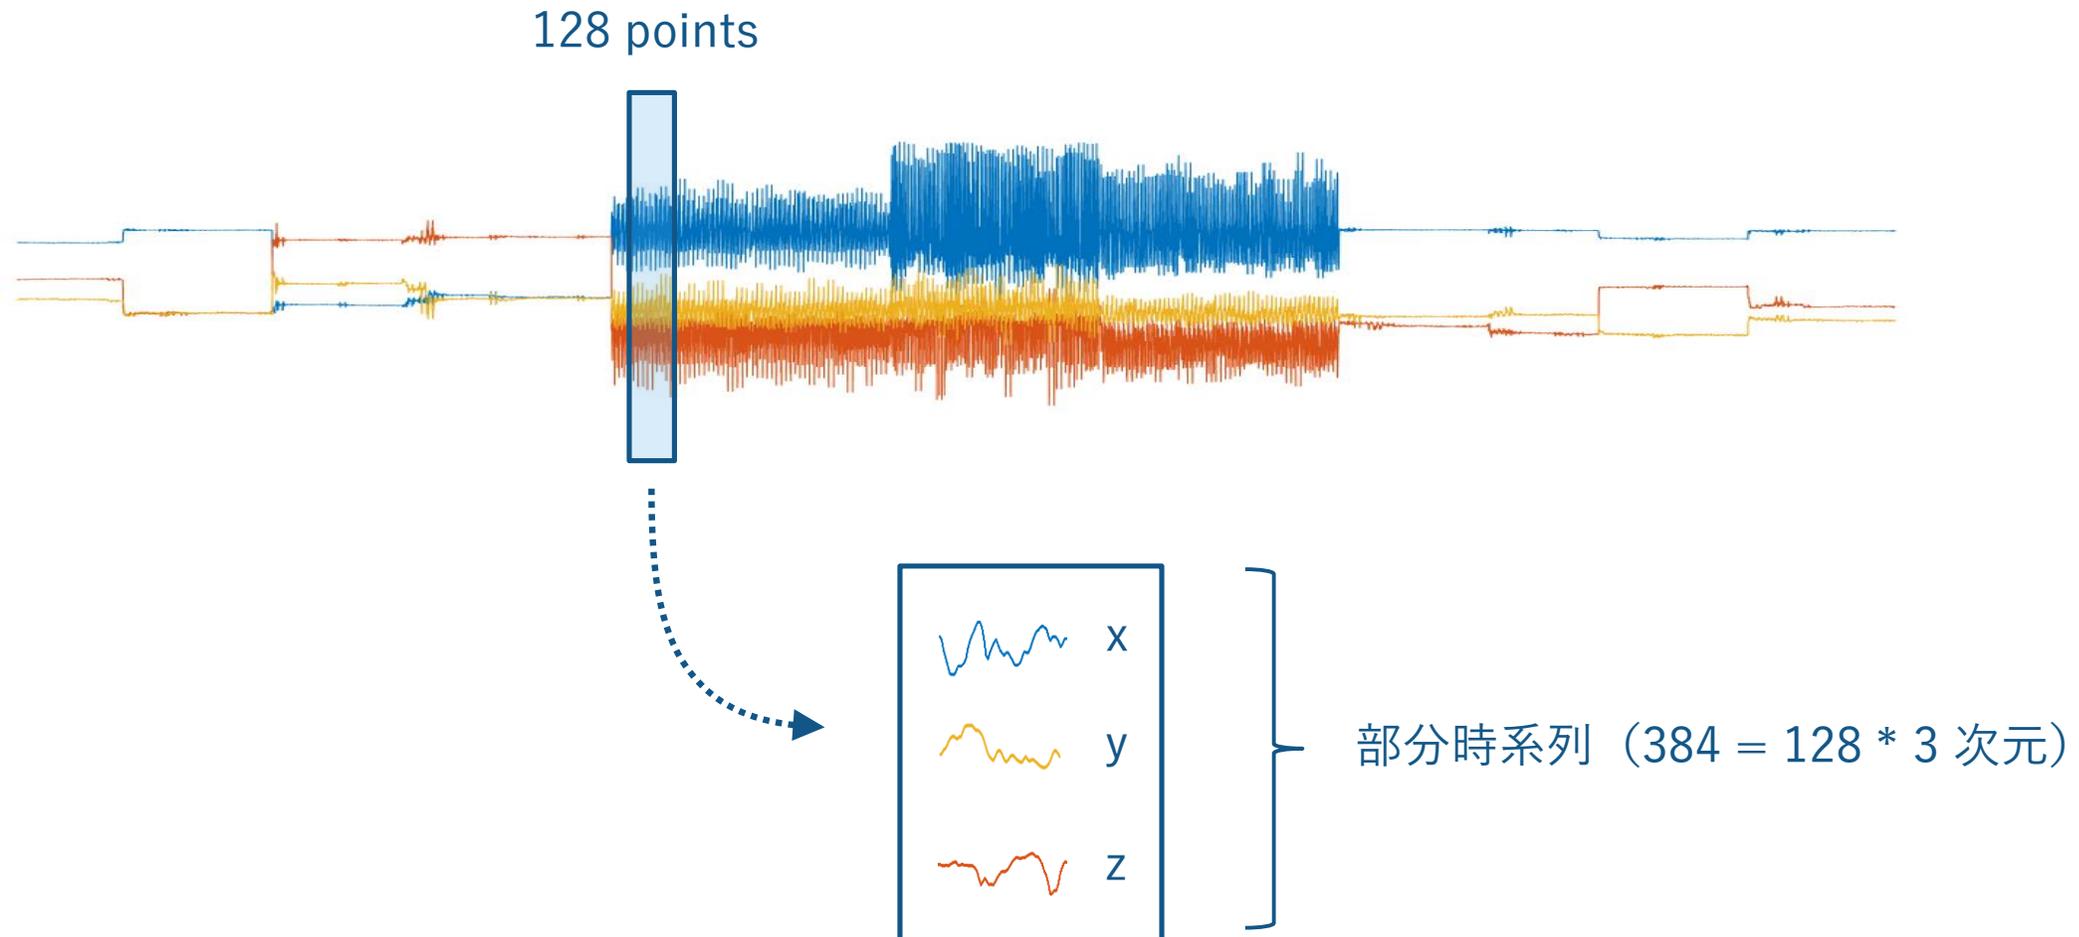
1. 部分時系列を作成 (3軸加速度センサーから窓幅128で切り出し)
2. ニューラルネットワークを使用して活動状態を識別



部分時系列 (窓幅 128)

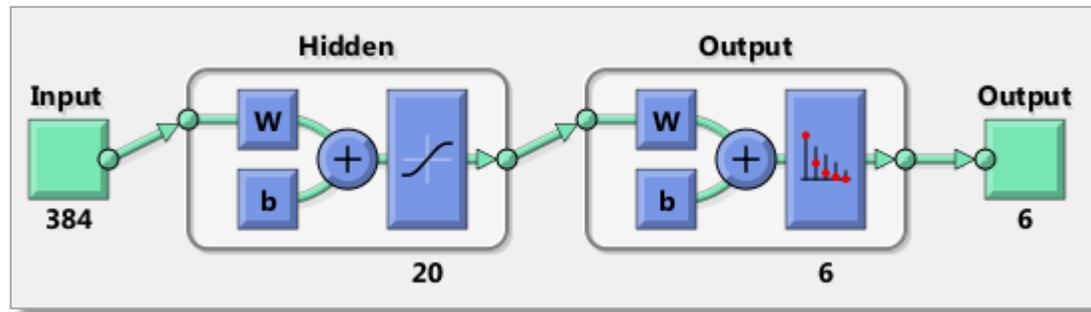


## 例2: 人の活動状態の識別



## 例2: 人の活動状態の識別

- 加速度センサーから人の活動状態を識別



```
>> net = patternnet(20);
>> net = train(net, x, t);
>> t_hat = net(x);
>> plotconfusion(t, t_hat)
```

入力: 384次元  
部分時系列 (加速度)

⋮	⋮	⋮	⋮	⋮

出力: 6次元  
人の活動状態 (ラベル)

1	0	0	0	0
0	0	1	0	0
0	1	0	0	0
0	0	0	0	0
0	0	0	1	1
0	0	0	0	0

## 例2: 人の活動状態の識別

### ■ 混合行列

Accuracy : 0.81371

歩行	349	110	28	3	6	0
階段-上り	66	355	41	8	1	0
階段-下り	9	61	339	8	3	0
着席	1	23	0	360	107	0
直立	0	1	0	73	458	0
寝る	0	0	0	0	0	537
	歩行	階段-上り	階段-下り	着席	直立	寝る

2層のニューラルネットワーク

Accuracy : 0.84323

歩行	412	27	25	11	21	0
階段-上り	49	397	25	0	0	0
階段-下り	13	74	333	0	0	0
着席	1	17	0	382	86	5
直立	5	0	0	103	424	0
寝る	0	0	0	0	0	537
	歩行	階段-上り	階段-下り	着席	直立	寝る

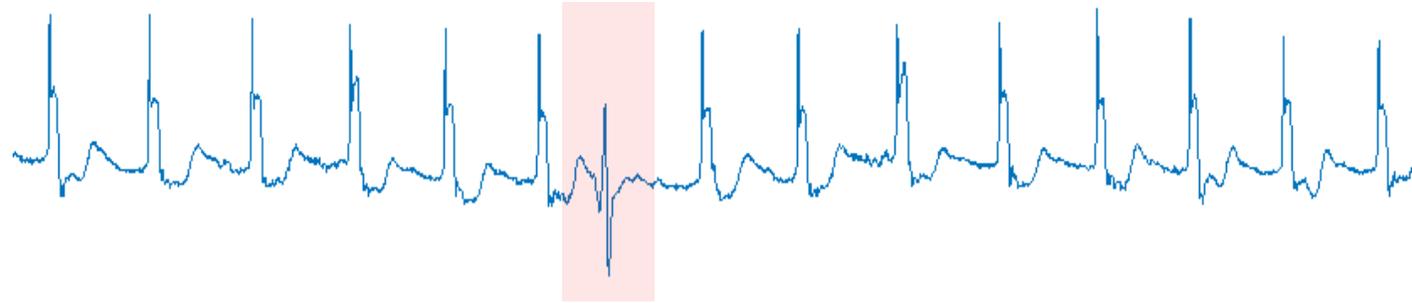
オートエンコーダ

# Outline

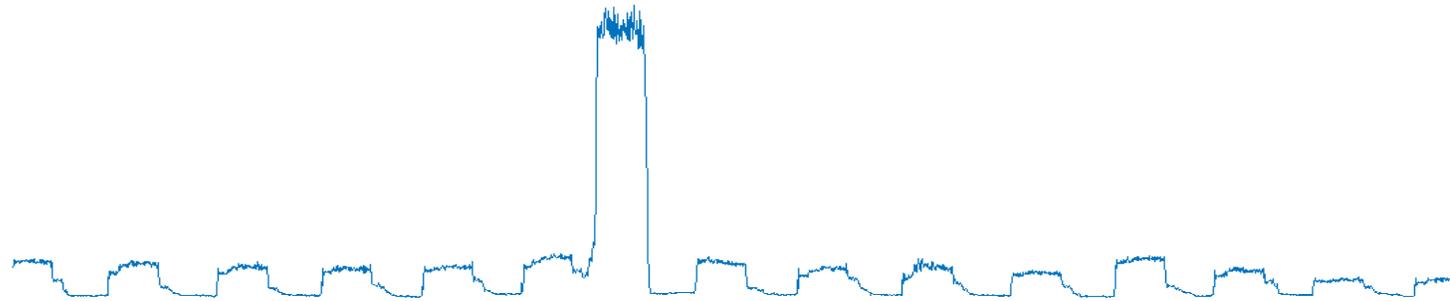
- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の数値の分類
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の**信号**データの**異常検出**
  - オートエンコーダ
- Case4: 画像データの分類と異常検出
  - CNN と 転移学習
  - 他のアルゴリズム

# センサーデータからの異常検出

心電図



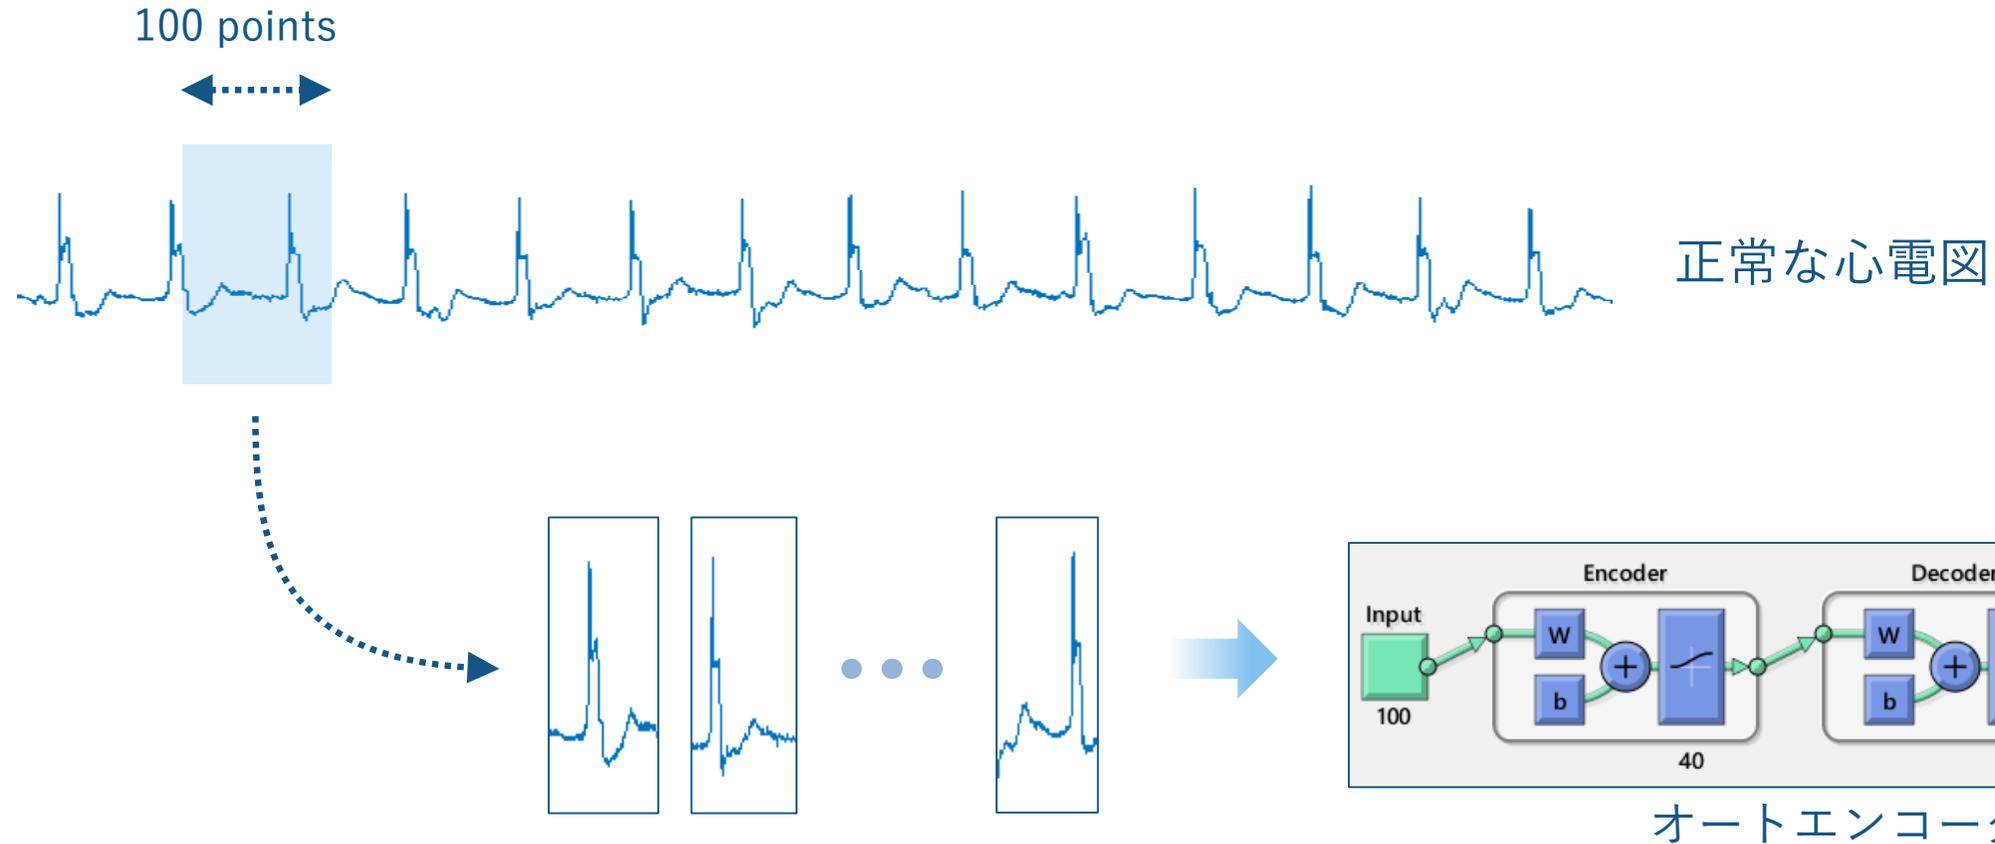
異常度



Keogh, E., Lin, J. and Fu, A. : HOT SAX : Efficiently Finding the Most Unusual Time Series Subsequence, in Proceedings of the Fifth IEEE International Conference on Data Mining, ICDM 05, pp.226-233

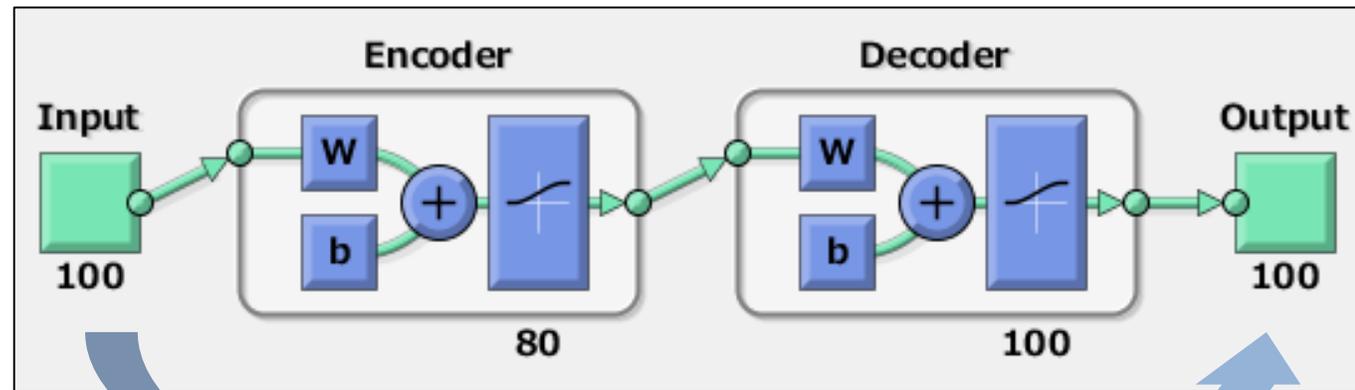
# オートエンコーダによる異常検出

- 正常な心電図から部分時系列を生成して、オートエンコーダで学習



# オートエンコーダとは

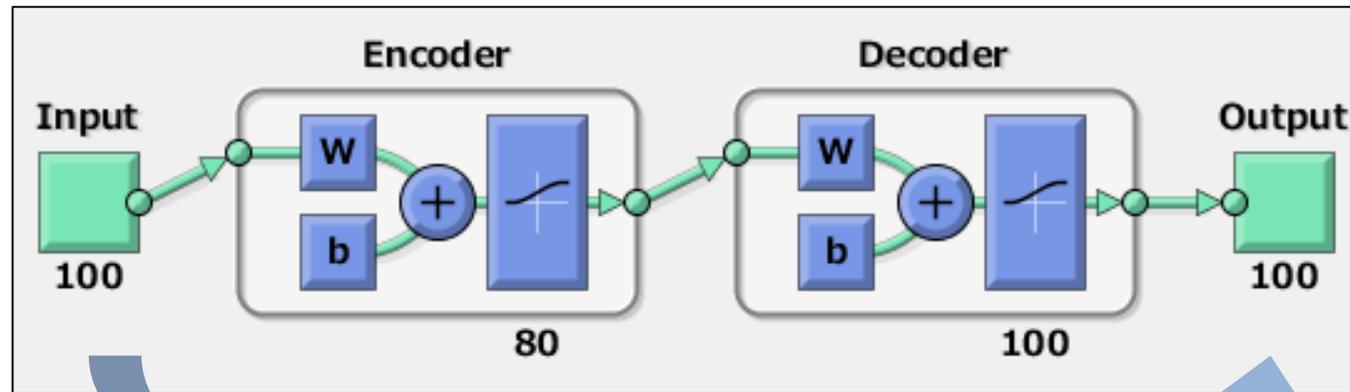
## オートエンコーダ



ネットワークが恒等写像になるように重みを学習

# オートエンコーダによる異常検出

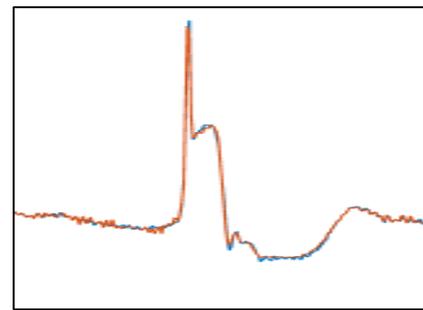
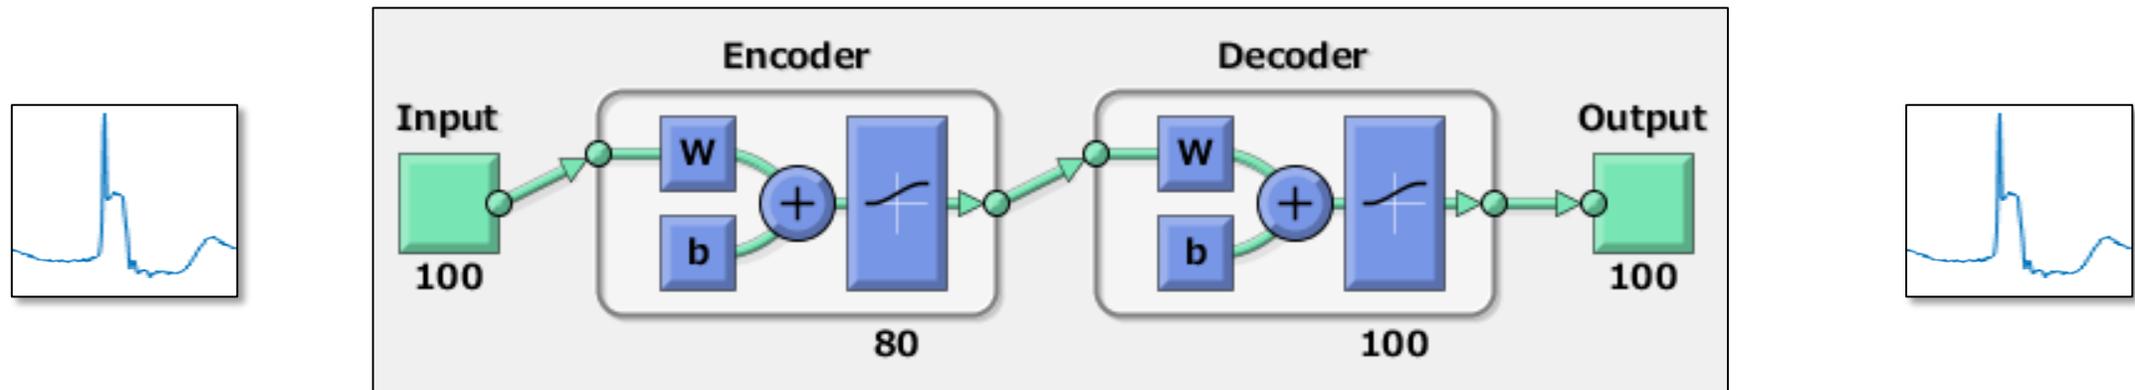
## オートエンコーダ



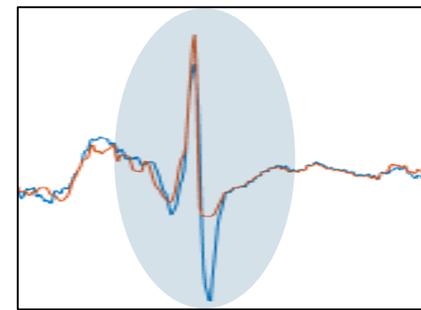
元の正常な波形を再生するようにウェイトを学習

# オートエンコーダによる異常検出

- 正常な波形の場合は元の波形をきれいに再生するが、異常な波形の場合はうまく再生できない！



正常な波形の場合



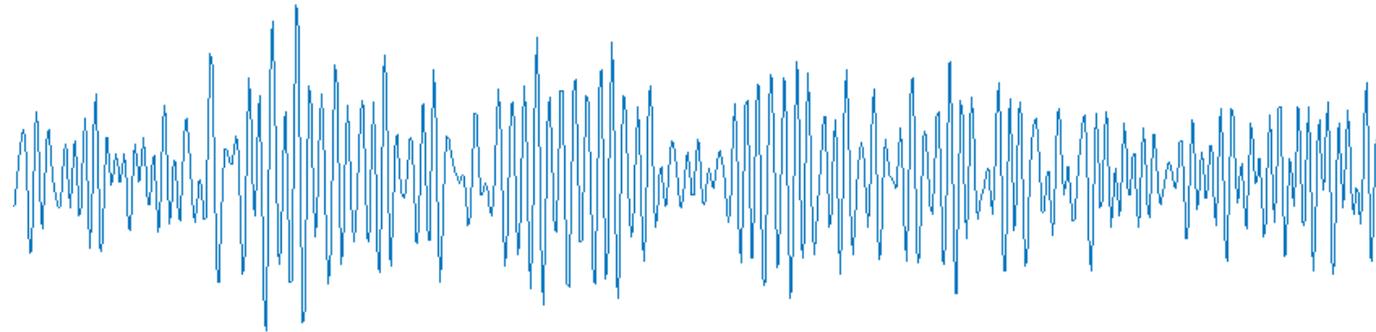
異常な波形の場合

異常な波形は正常な  
波形に戻そうとする

# 構造物の異常検出

- ある構造物に取り付けられた振動データの比較

正常



異常



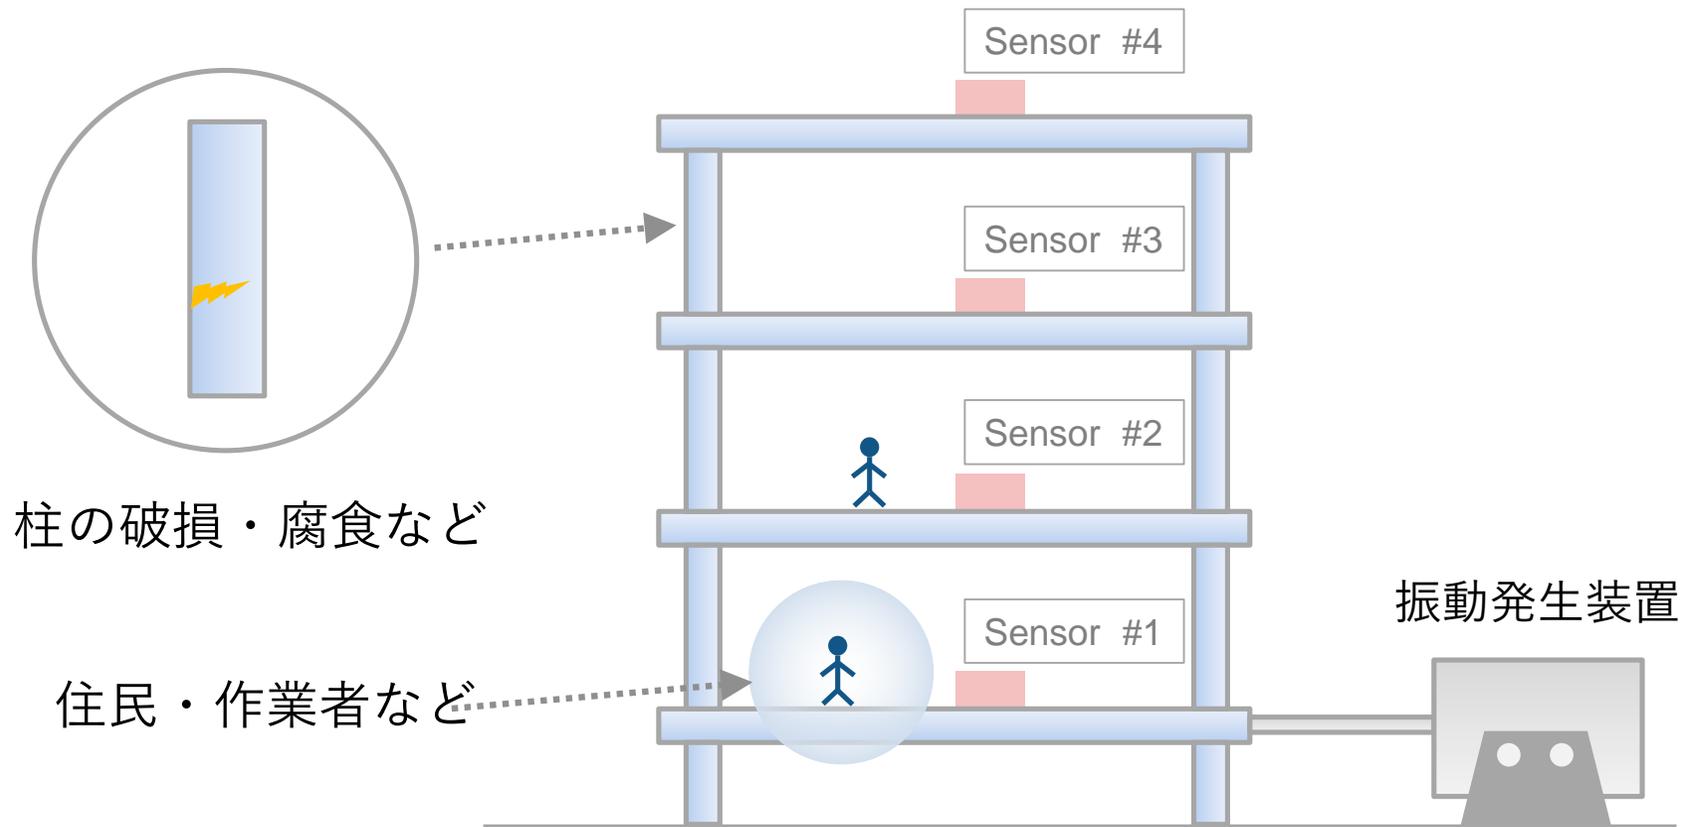
## 例3: 構造物ヘルスマニタリング



- 実験装置
  - 3階建ての建物の模型
  - 4ヶ所の加速度センサー
  - 1階部分に振動発生装置
  - 人工的な損傷状態の発生
- 実験目的
  - センサーによる異常検出

Reference: Figueiredo, E., Park, G., Figueiras, J., Farrar, C., & Worden, K. (2009). Structural Health Monitoring Algorithm Comparisons using Standard Data Sets. Los Alamos National Laboratory Report: LA-14393

## 例3: 構造物ヘルスマニタリング



Reference: Figueiredo, E., Park, G., Figueiras, J., Farrar, C., & Worden, K. (2009). Structural Health Monitoring Algorithm Comparisons using Standard Data Sets. Los Alamos National Laboratory Report: LA-14393

## 例3: 構造物ヘルスマニタリング

- 構造物のモデルにおいて、次の条件を変化させていくつかの状態を作成
  - 各階への重量 (Mass)
  - 柱の硬さの低減 (Stiffness reduction)

State	Description
#1	Baseline condition
#2	Mass = 1.2 kg at the base
#3	Mass = 1.2 kg on the 1st floor
#4	87.5% stiffness reduction in column 1BD
#5	87.5% stiffness reduction in column 1AD and 1BD
#6	87.5% stiffness reduction in column 2BD
#7	87.5% stiffness reduction in column 2AD and 2BD
#8	87.5% stiffness reduction in column 3BD
#9	87.5% stiffness reduction in column 3AD and 3BD

上記9パターンのそれぞれで10回の実験を繰り返し、合計90回の実験を行った

## 例3: 構造物ヘルスマニタリング

- State #1 を正常データとして、異常データが検知できるか調べたい

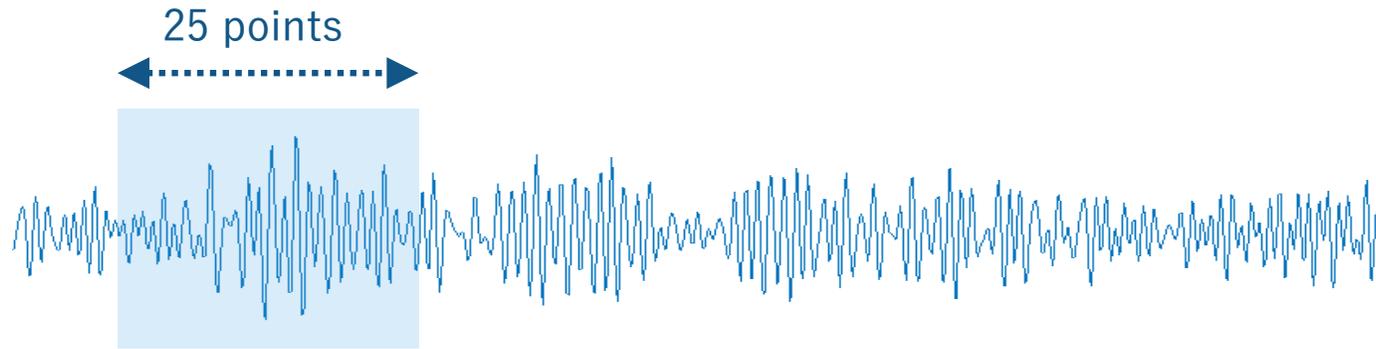
State	Description
#1	Baseline condition
#2	Mass = 1.2 kg at the base
#3	Mass = 1.2 kg on the 1st floor
#4	87.5% stiffness reduction in column 1BD
#5	87.5% stiffness reduction in column 1AD and 1BD
#6	87.5% stiffness reduction in column 2BD
#7	87.5% stiffness reduction in column 2AD and 2BD
#8	87.5% stiffness reduction in column 3BD
#9	87.5% stiffness reduction in column 3AD and 3BD

正常データ

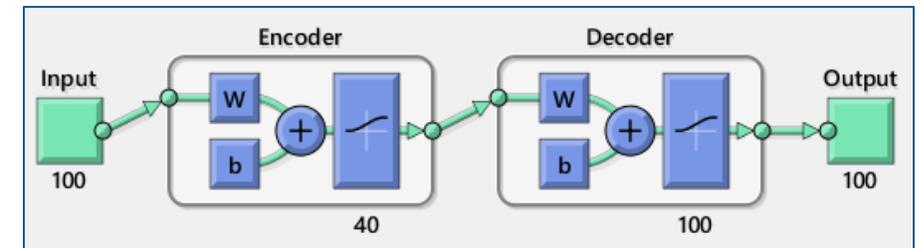
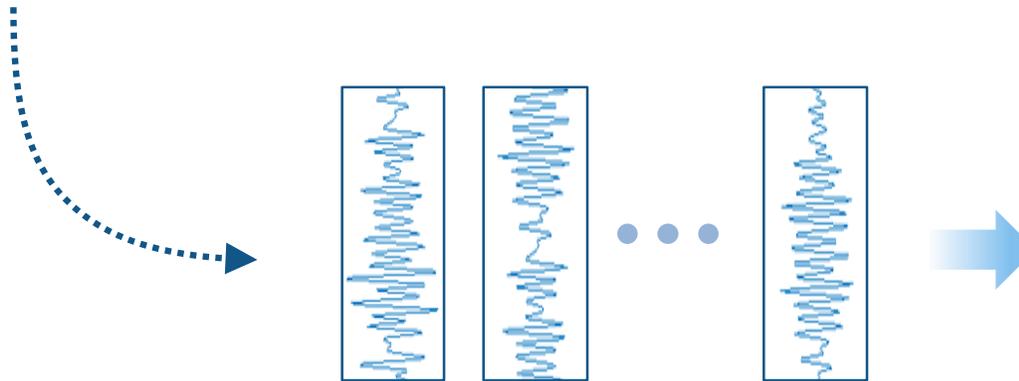
異常データ

# オートエンコーダによる異常検出

- 正常な振動データから部分時系列を生成して、オートエンコーダで学習



正常な振動データ



オートエンコーダ

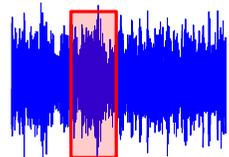
# オートエンコーダによる異常検出



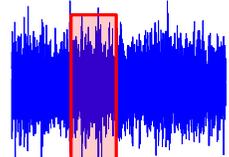
Sensor #1



Sensor #2

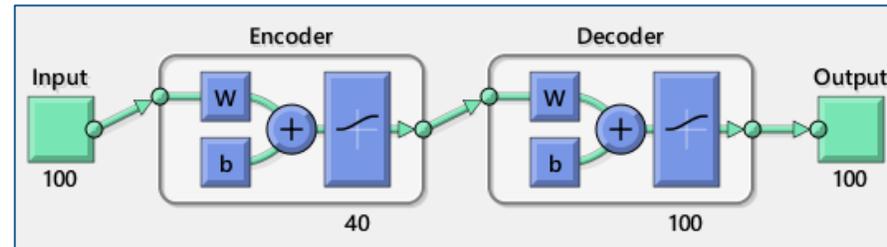


Sensor #3



Sensor #4

## オートエンコーダ



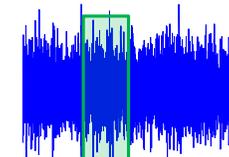
Sensor #1



Sensor #2



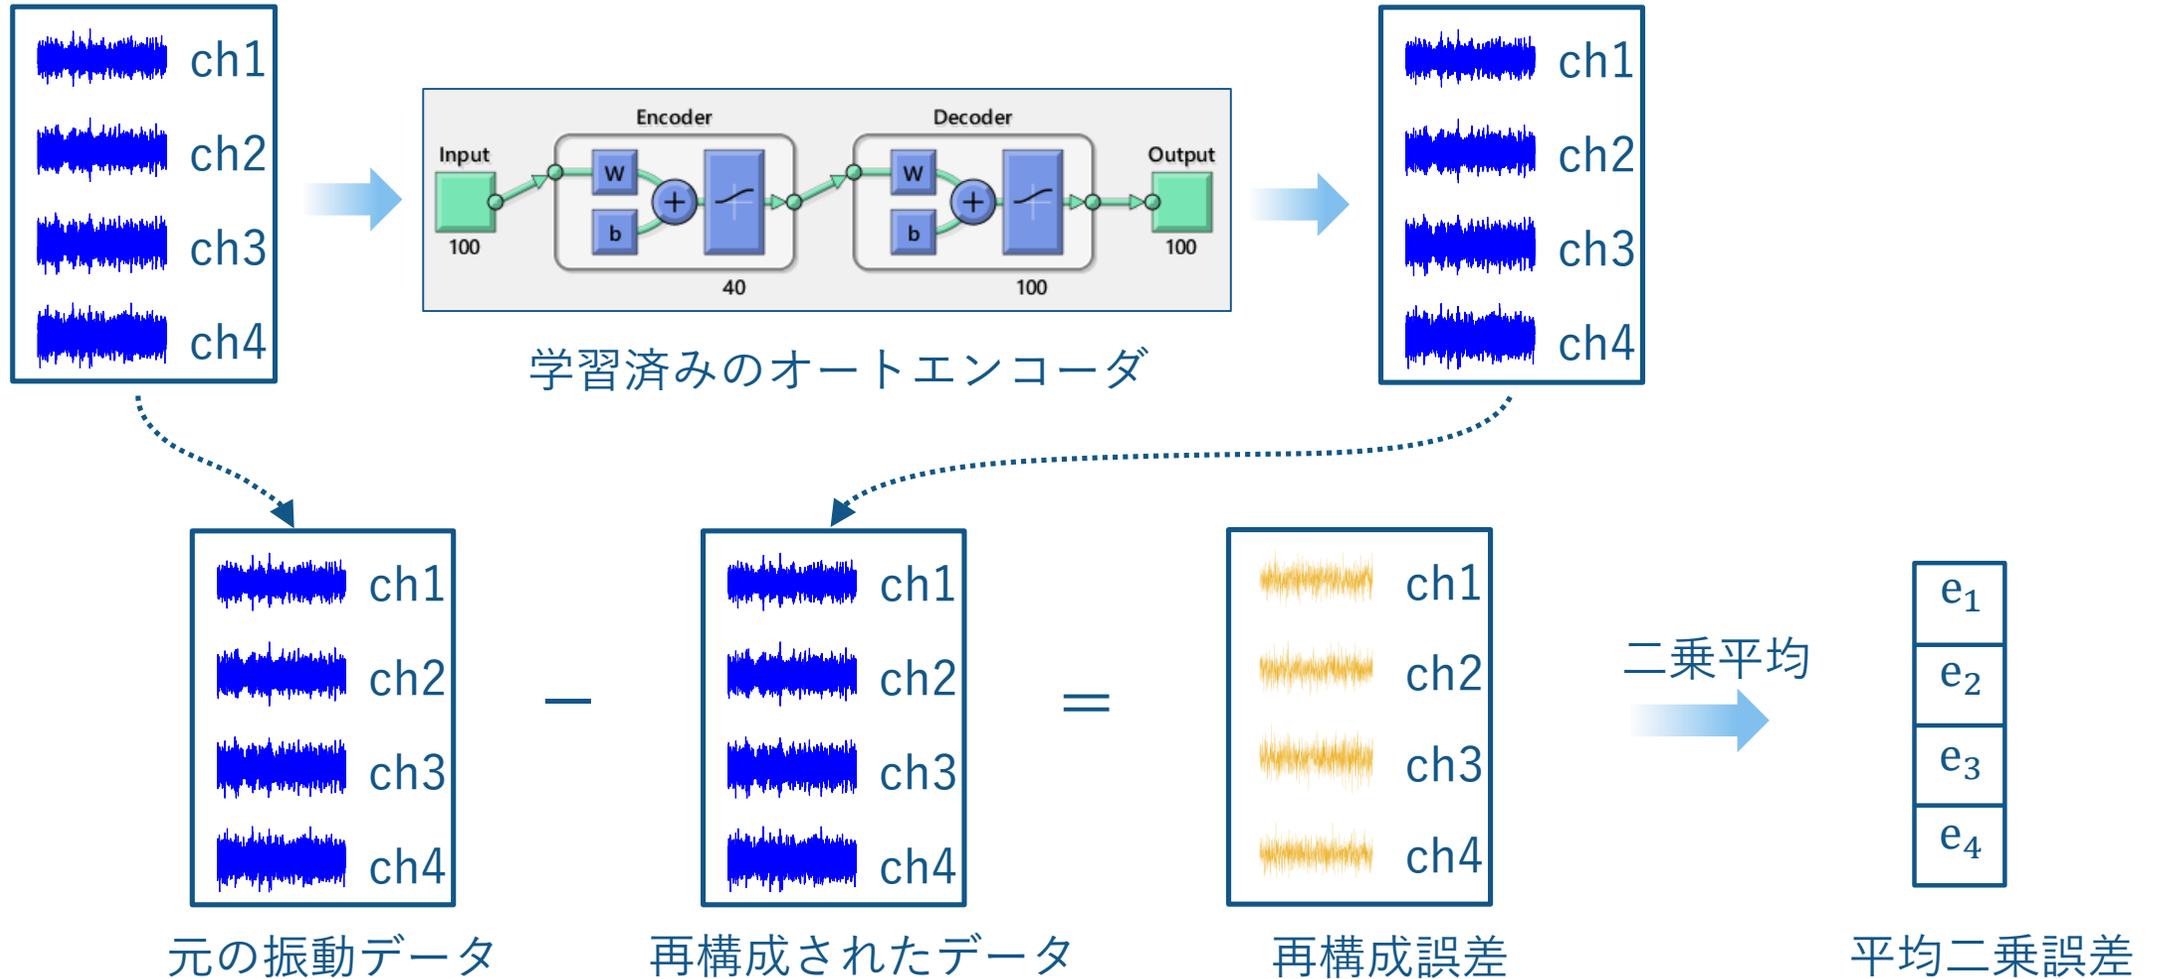
Sensor #3



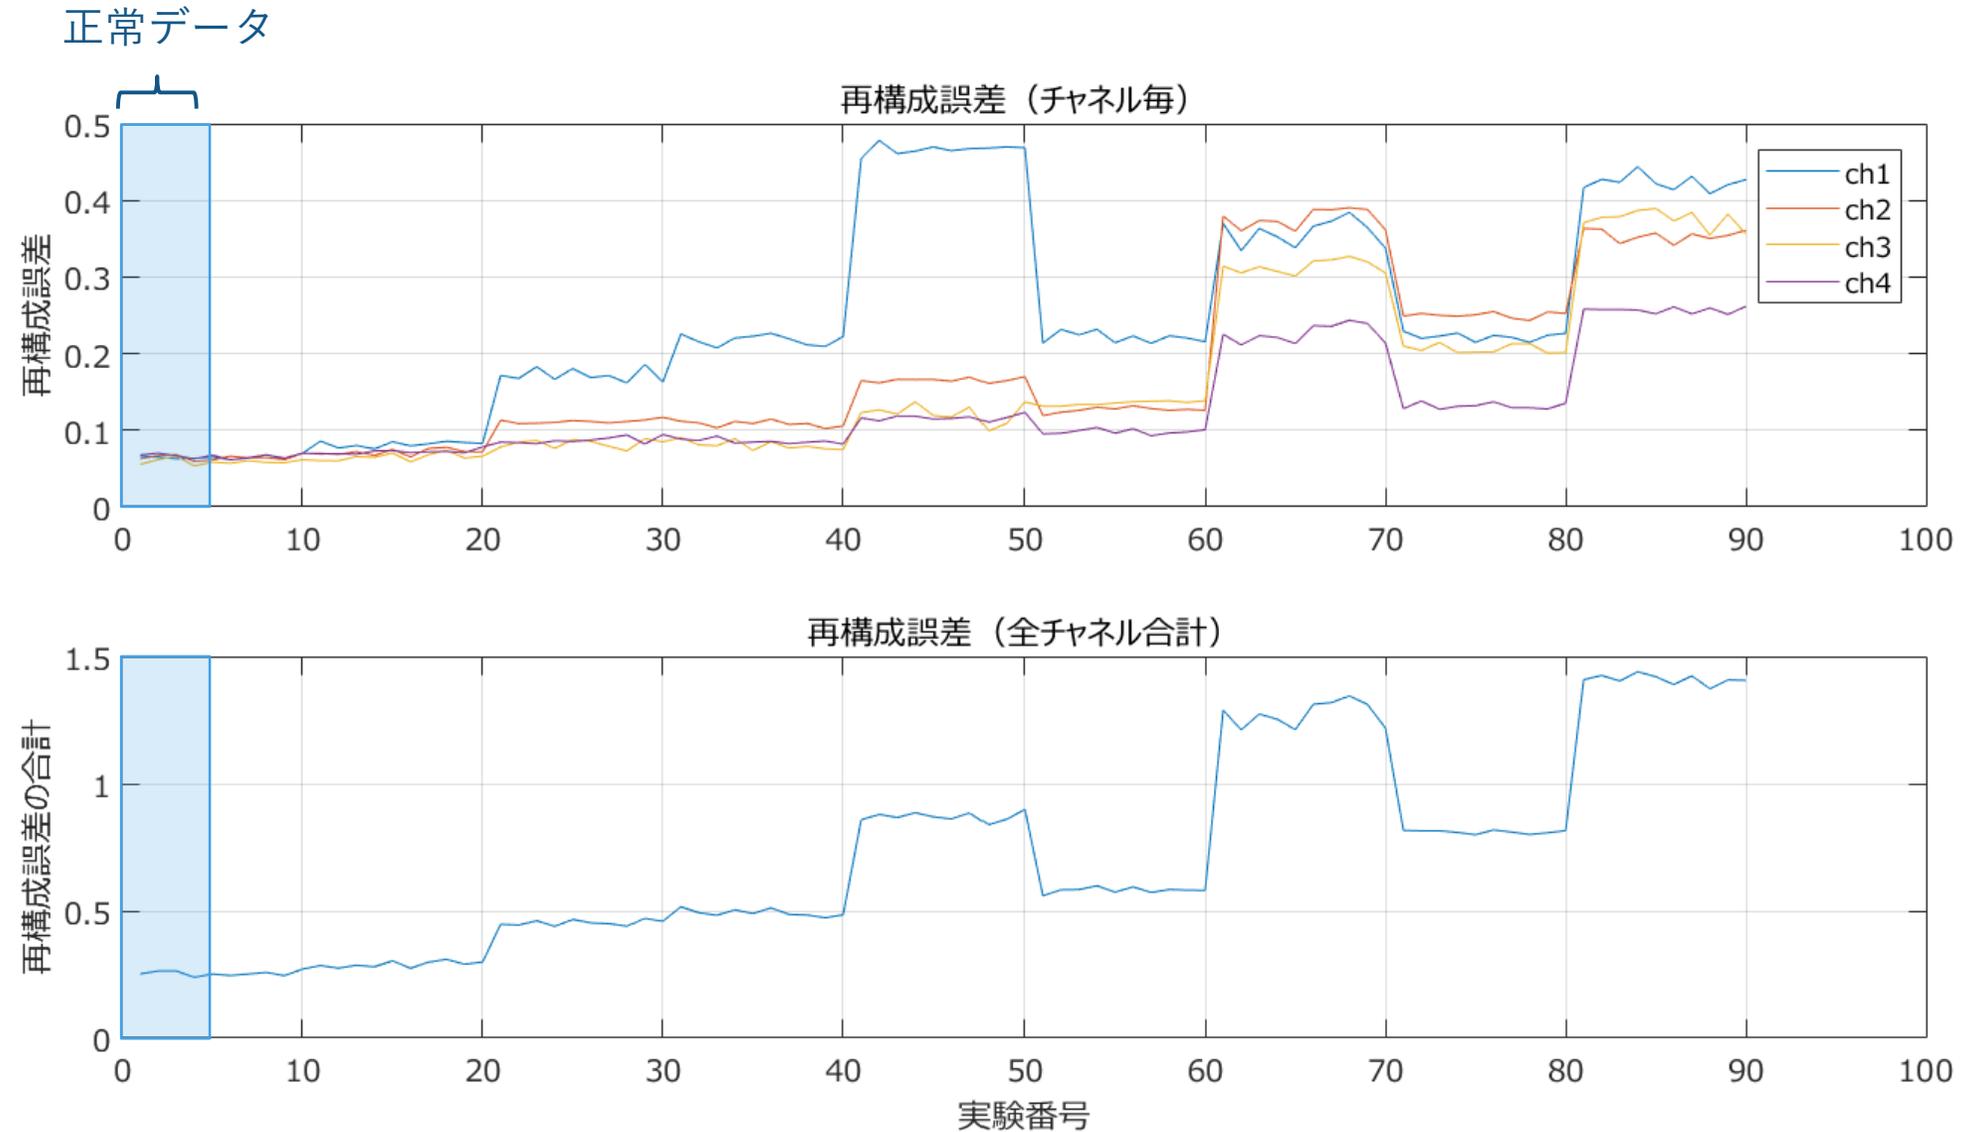
Sensor #4

# オートエンコーダによる異常検出

- オートエンコーダから再構成誤差を算出

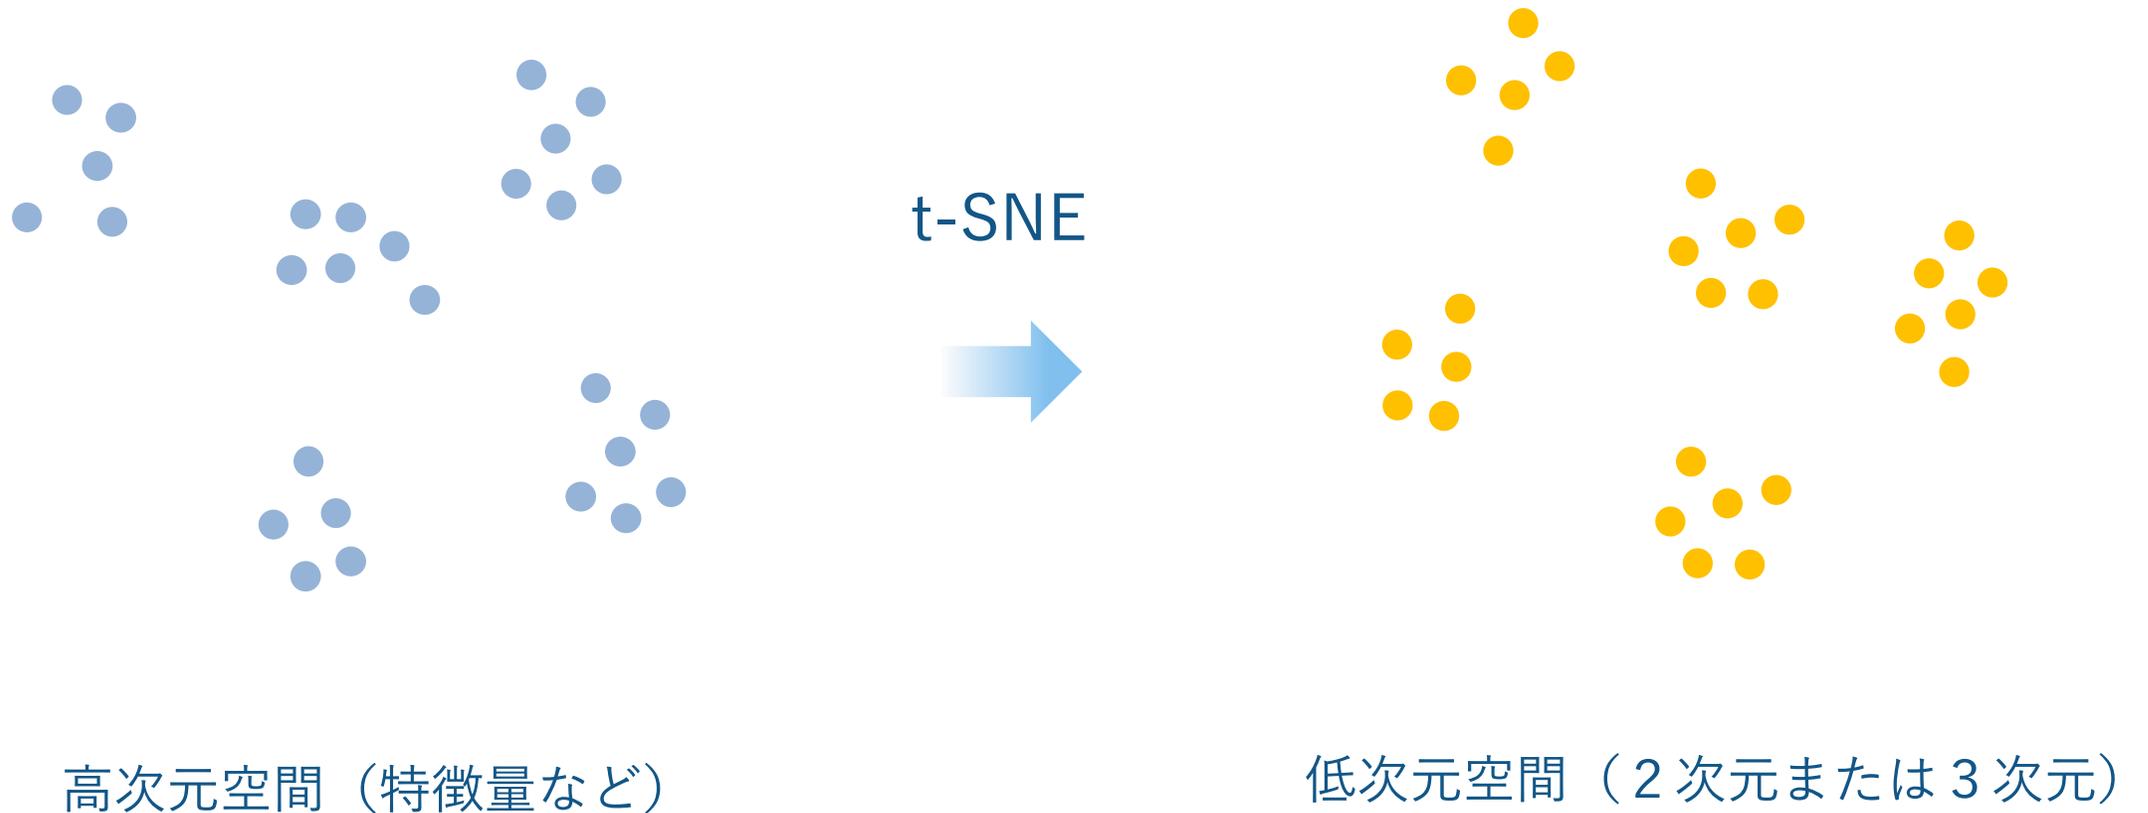


# オートエンコーダによる異常検出



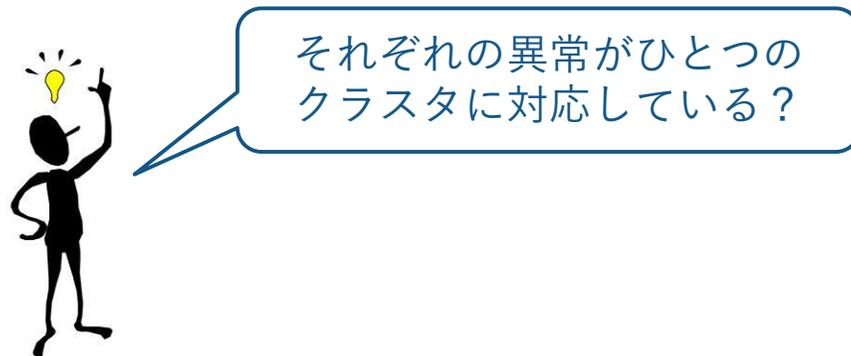
# t-SNE とは

- 観測できない高次元データを低次元にマップする手法（次元削減手法）

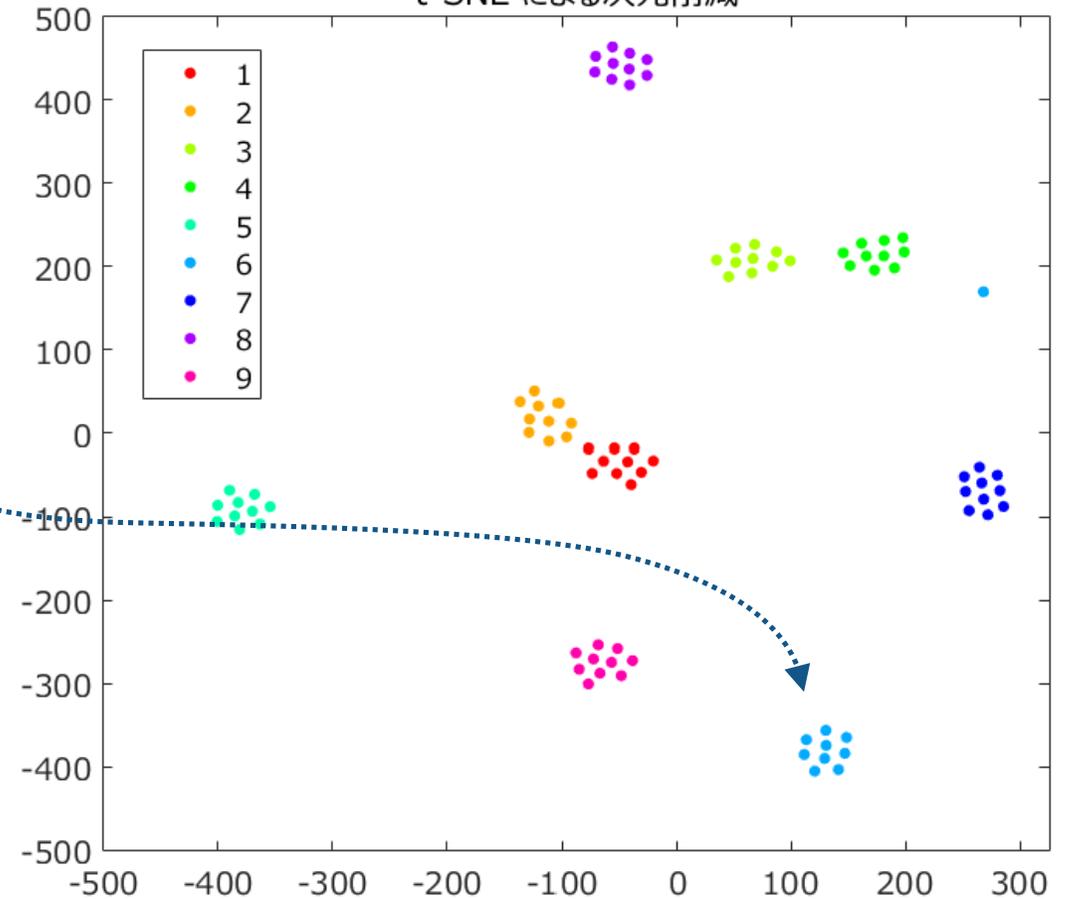


# t-SNE による異常データのクラスタリング

State	Description
#1	Baseline condition
#2	Mass = 1.2 kg at the base
#3	Mass = 1.2 kg on the 1st floor
#4	87.5% stiffness reduction in column 1BD
#5	87.5% stiffness reduction in column 1AD and 1BD
#6	87.5% stiffness reduction in column 2BD
#7	87.5% stiffness reduction in column 2AD and 2BD
#8	87.5% stiffness reduction in column 3BD
#9	87.5% stiffness reduction in column 3AD and 3BD



t-SNE による次元削減

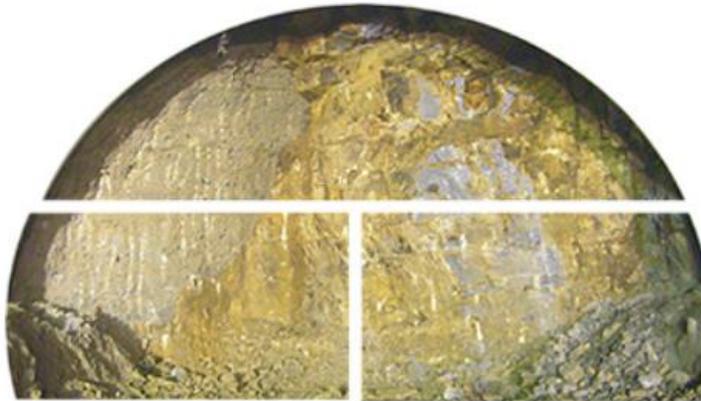


# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の数値の分類
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の信号データの異常検出
  - オートエンコーダ
- Case4: **画像データの分類と異常検出**
  - **CNN** と 転移学習
  - 他のアルゴリズム

# 画像分類の応用例: 株式会社大林組 様

山岳トンネル工事の切羽（掘削面）評価にディープラーニングを適用



従来の切羽の評価領域（上方、左右の3分割）



AlexNet(※3)による切羽の評価領域（分割数は撮影時の画素数によって異なります）

- 風化変質（4分類）
- 割目間隔（5分類）
- 割目状態（5分類）

AlexNet + SVM の転移学習  
割目状態では **89%** の的中率

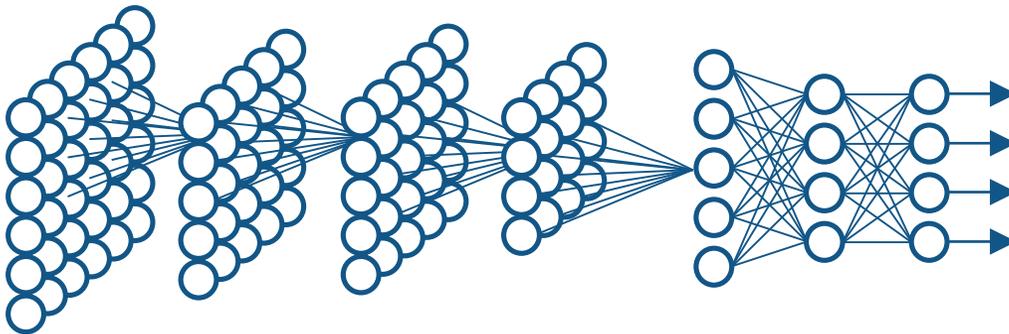
※大林組様プレスリリースより参照

[http://www.obayashi.co.jp/press/news20170912\\_01](http://www.obayashi.co.jp/press/news20170912_01)

# 畳み込みニューラルネットワーク (Convolutional Neural Networks) R2016a

## ■ 畳み込みニューラルネットワーク (CNN) とは `net.Layers`

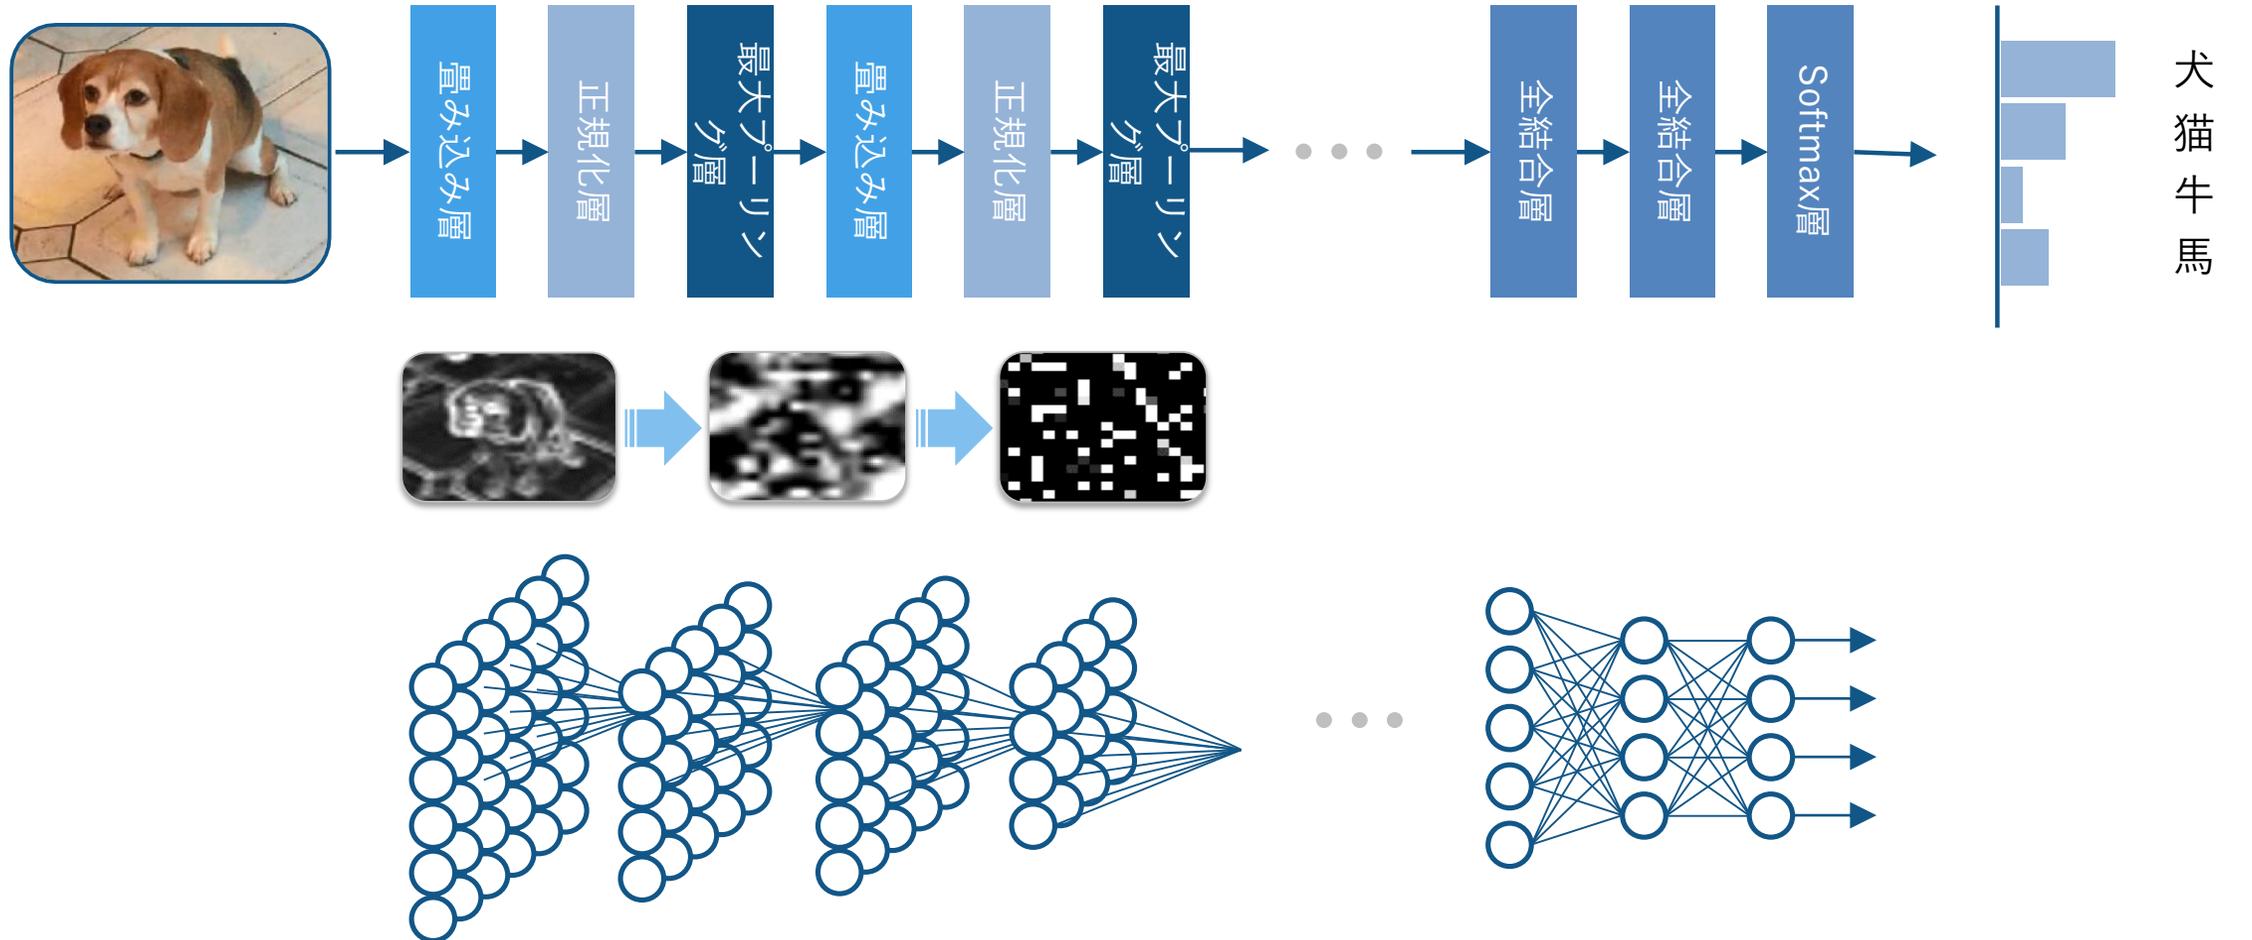
- 畳み込み層・プーリング層などを積層したネットワーク
- 分類、回帰の課題に適用
- 画像認識の分野で高い性能



11x1 Layer array with layers:

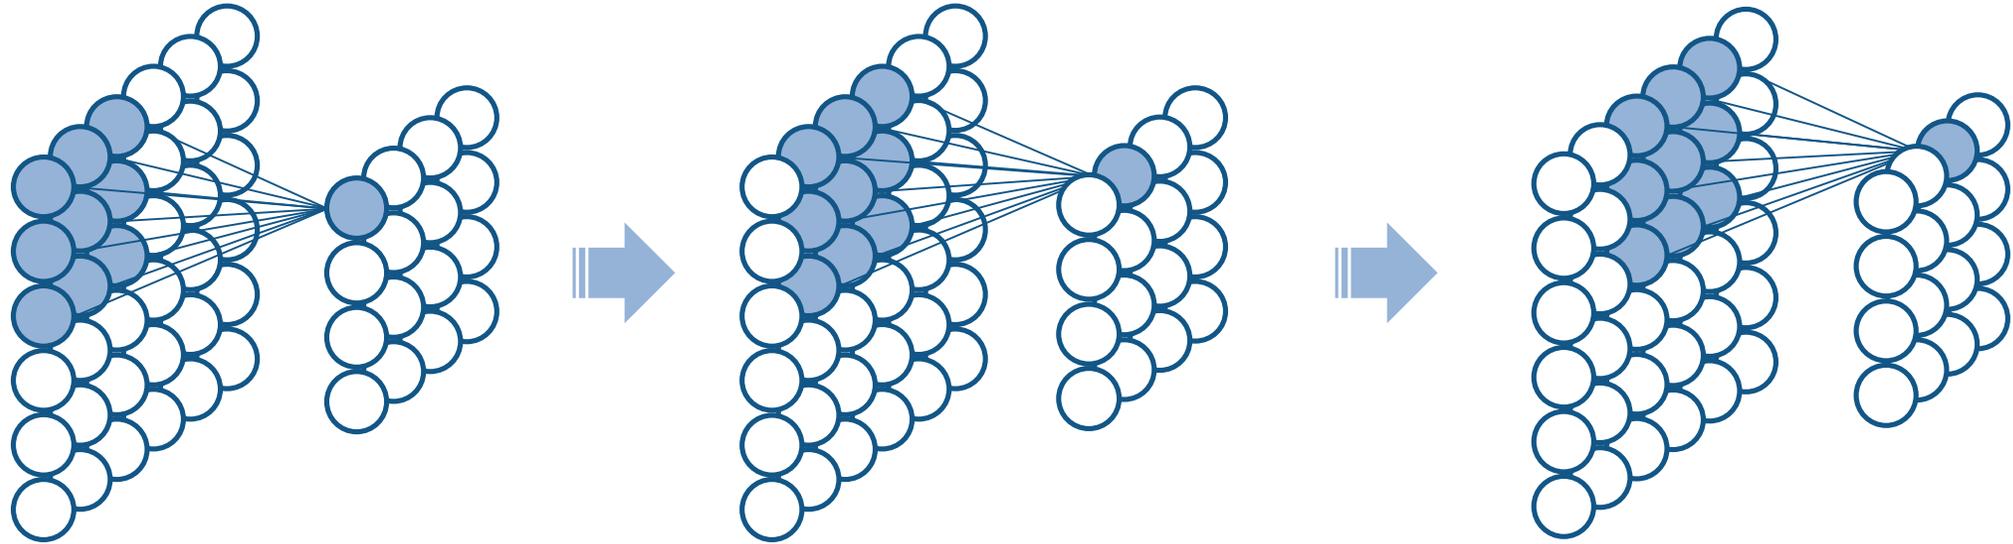
1	'imageinput'	Image Input
2	'conv'	Convolution
3	'relu'	ReLU
4	'conv'	Convolution
5	'relu'	ReLU
6	'maxpool'	Max Pooling
7	'conv'	Convolution
8	'relu'	ReLU
9	'fc'	Fully Connected
10	'softmax'	Softmax
11	'classoutput'	Classification Output

# 畳み込みニューラルネットワーク (Convolutional Neural Networks)



# 畳み込みニューラルネットワークの主な層

畳み込み層、プーリング層



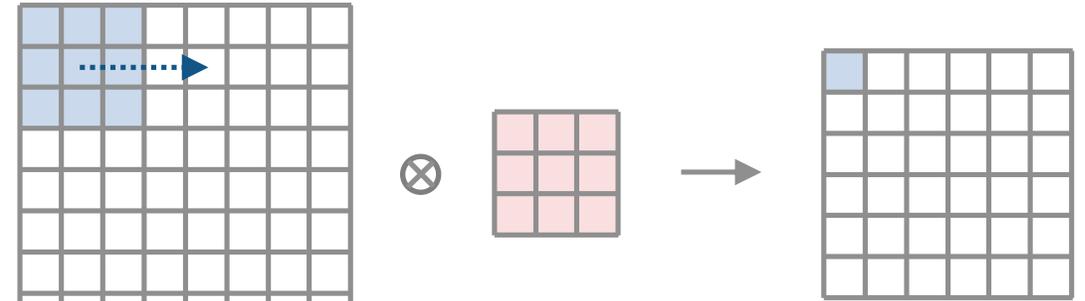
層と層の間を一部のみ連結してウェイトを共有することで、ニューラルネットワークを用いて畳み込

# 畳み込みニューラルネットワークの主な層

畳み込み層、プーリング層

## Convolution Layer (畳み込み層)

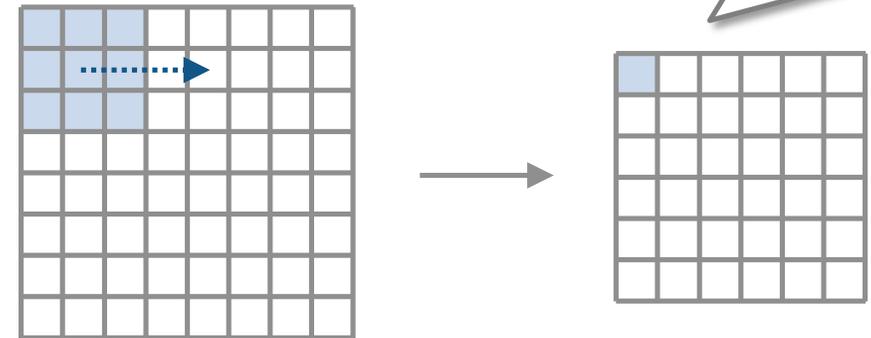
- 画像のフィルタ処理に相当する処理
- 特徴抽出器としての役割



最大値を出力: Max Pooling  
平均値を出力: Average Pooling  
Pooling

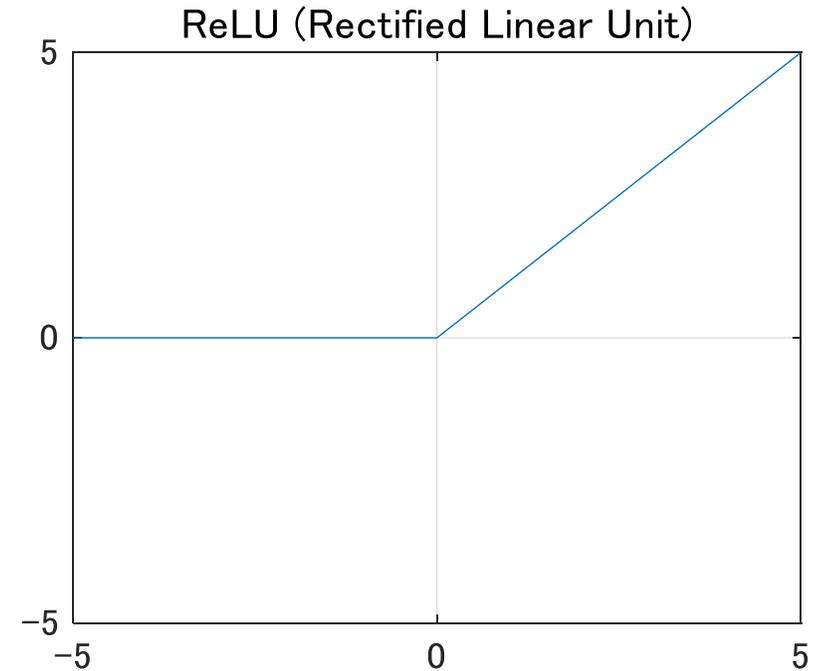
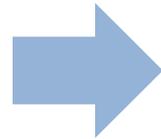
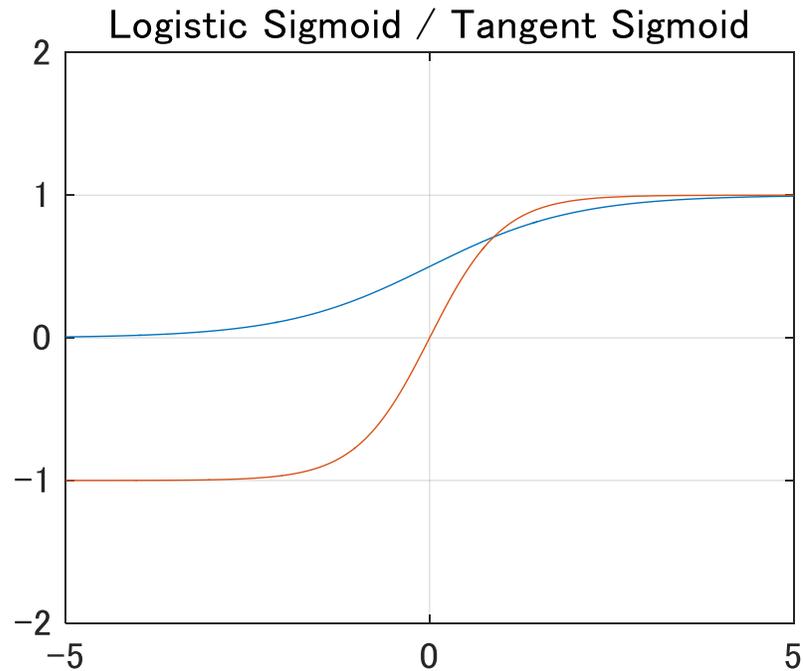
## Pooling Layer (プーリング層)

- 領域内の最大値または平均値を出力
- 平行移動等に対するロバスト性に関係
- スライドと呼ばれる間引きを行うこともある



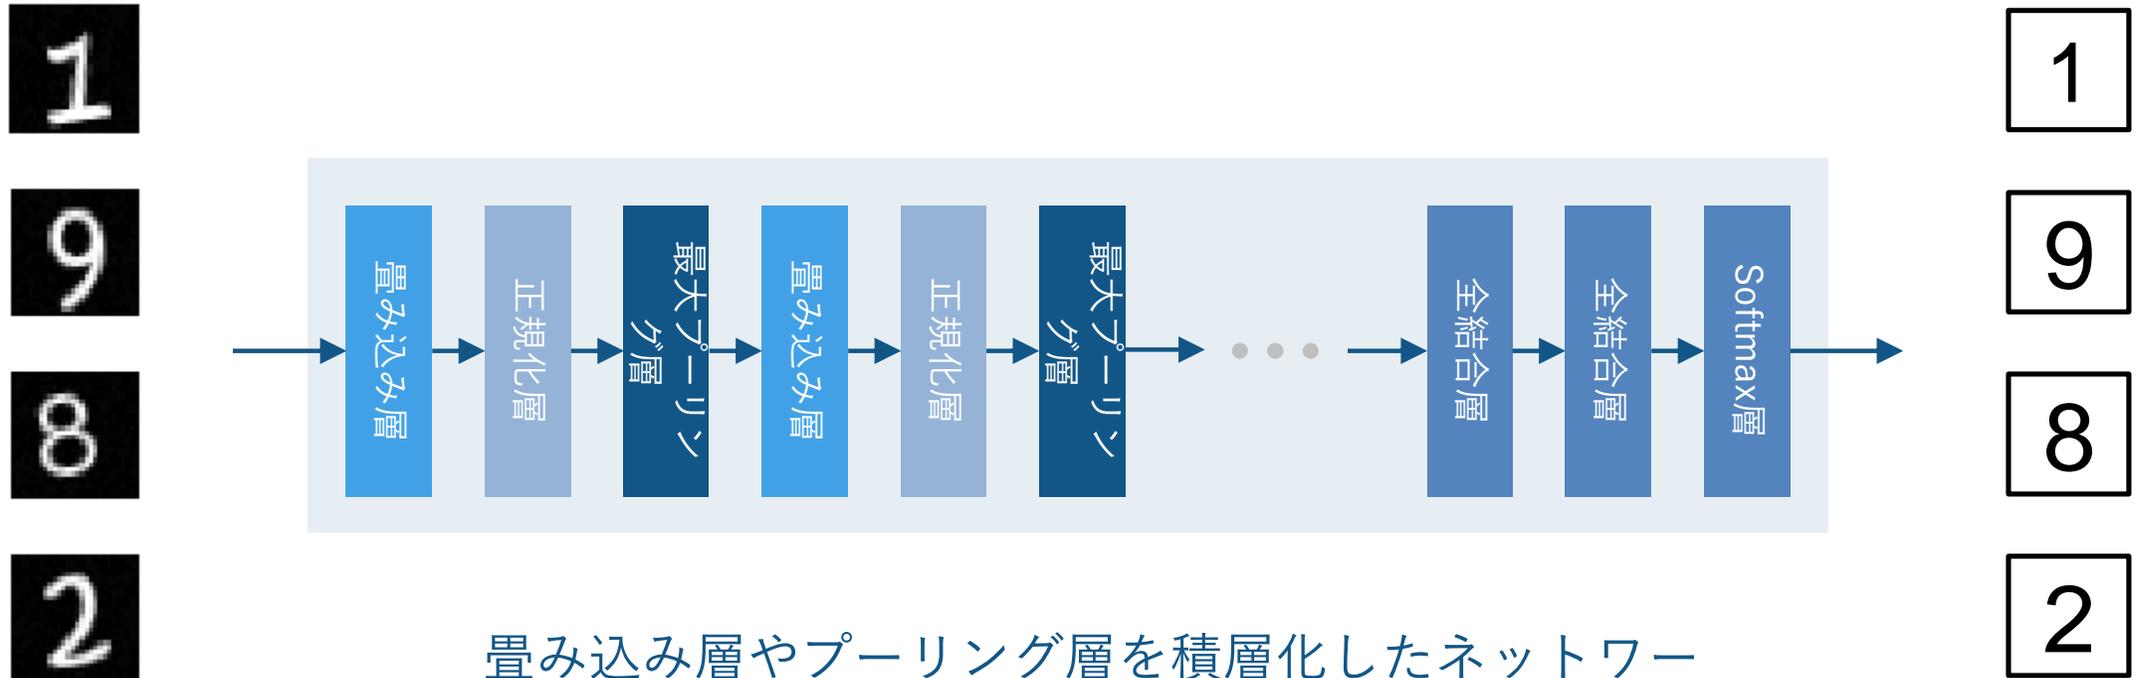
# 畳み込みニューラルネットワークの主な層 活性化関数 - ReLU 層 (Rectified Linear Unit)

- Logistic Sigmoid のように値が飽和する関数より、  
ReLU の方が学習が早く進行



## 例4: 手書き文字の認識

- 畳み込みニューラルネットによる手書き文字の認識



手書き文字  
28 x 28 pixel

畳み込み層やプーリング層を積層化したネットワークを定義  
誤差逆伝搬法により学習

整数 (0-9)

# 畳み込みニューラルネットワークの構築と学習

- 28×28 ピクセルの画像（数字）を認識させる例題でのネットワーク構築の例

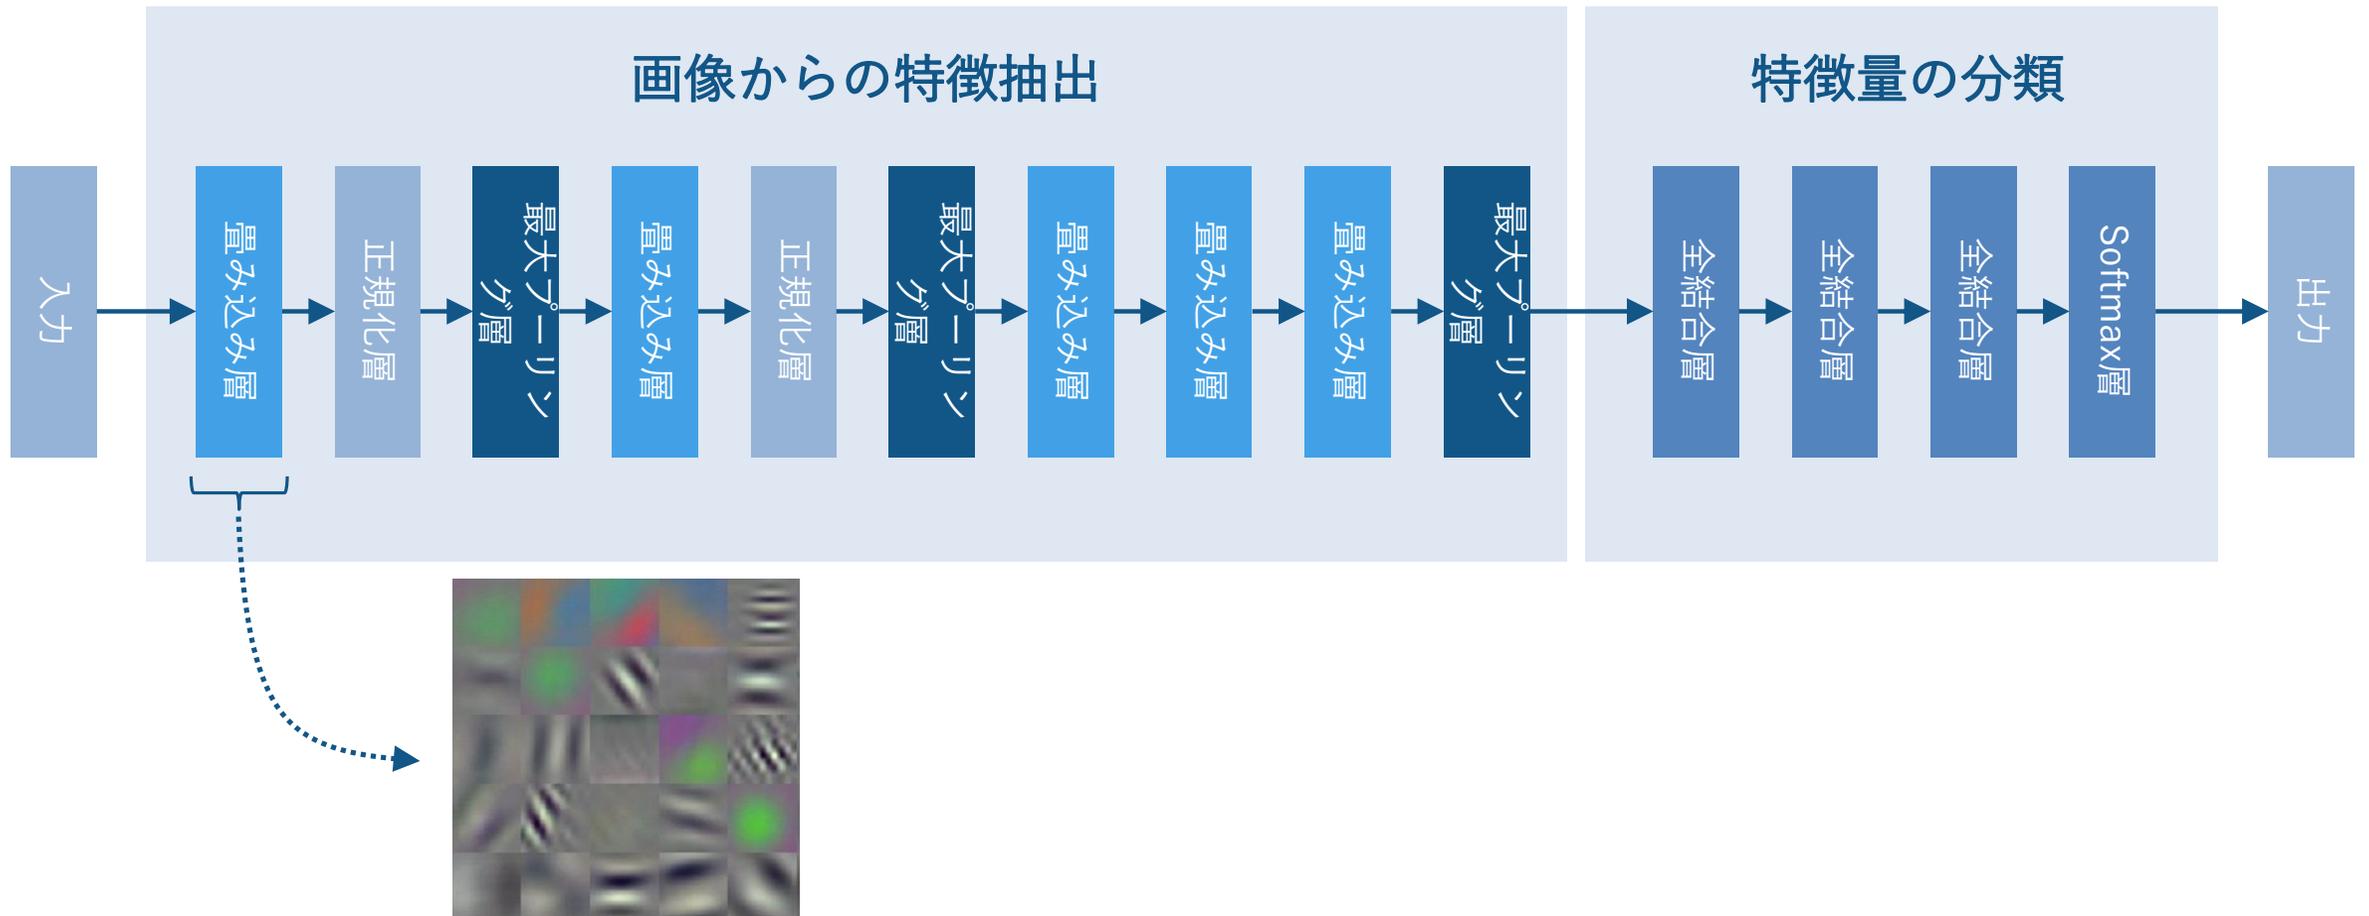
```
layers = [ ...  
    imageInputLayer([28 28 1], 'Normalization', 'none');  
    convolution2dLayer(5, 20);  
    reluLayer();  
    maxPooling2dLayer(2, 'Stride', 2);  
    fullyConnectedLayer(10);  
    softmaxLayer();  
    classificationLayer()];
```

```
opts = trainingOptions('sgdm', 'MaxEpochs', 50);  
net = trainNetwork(XTrain, TTrain, layers, opts);
```



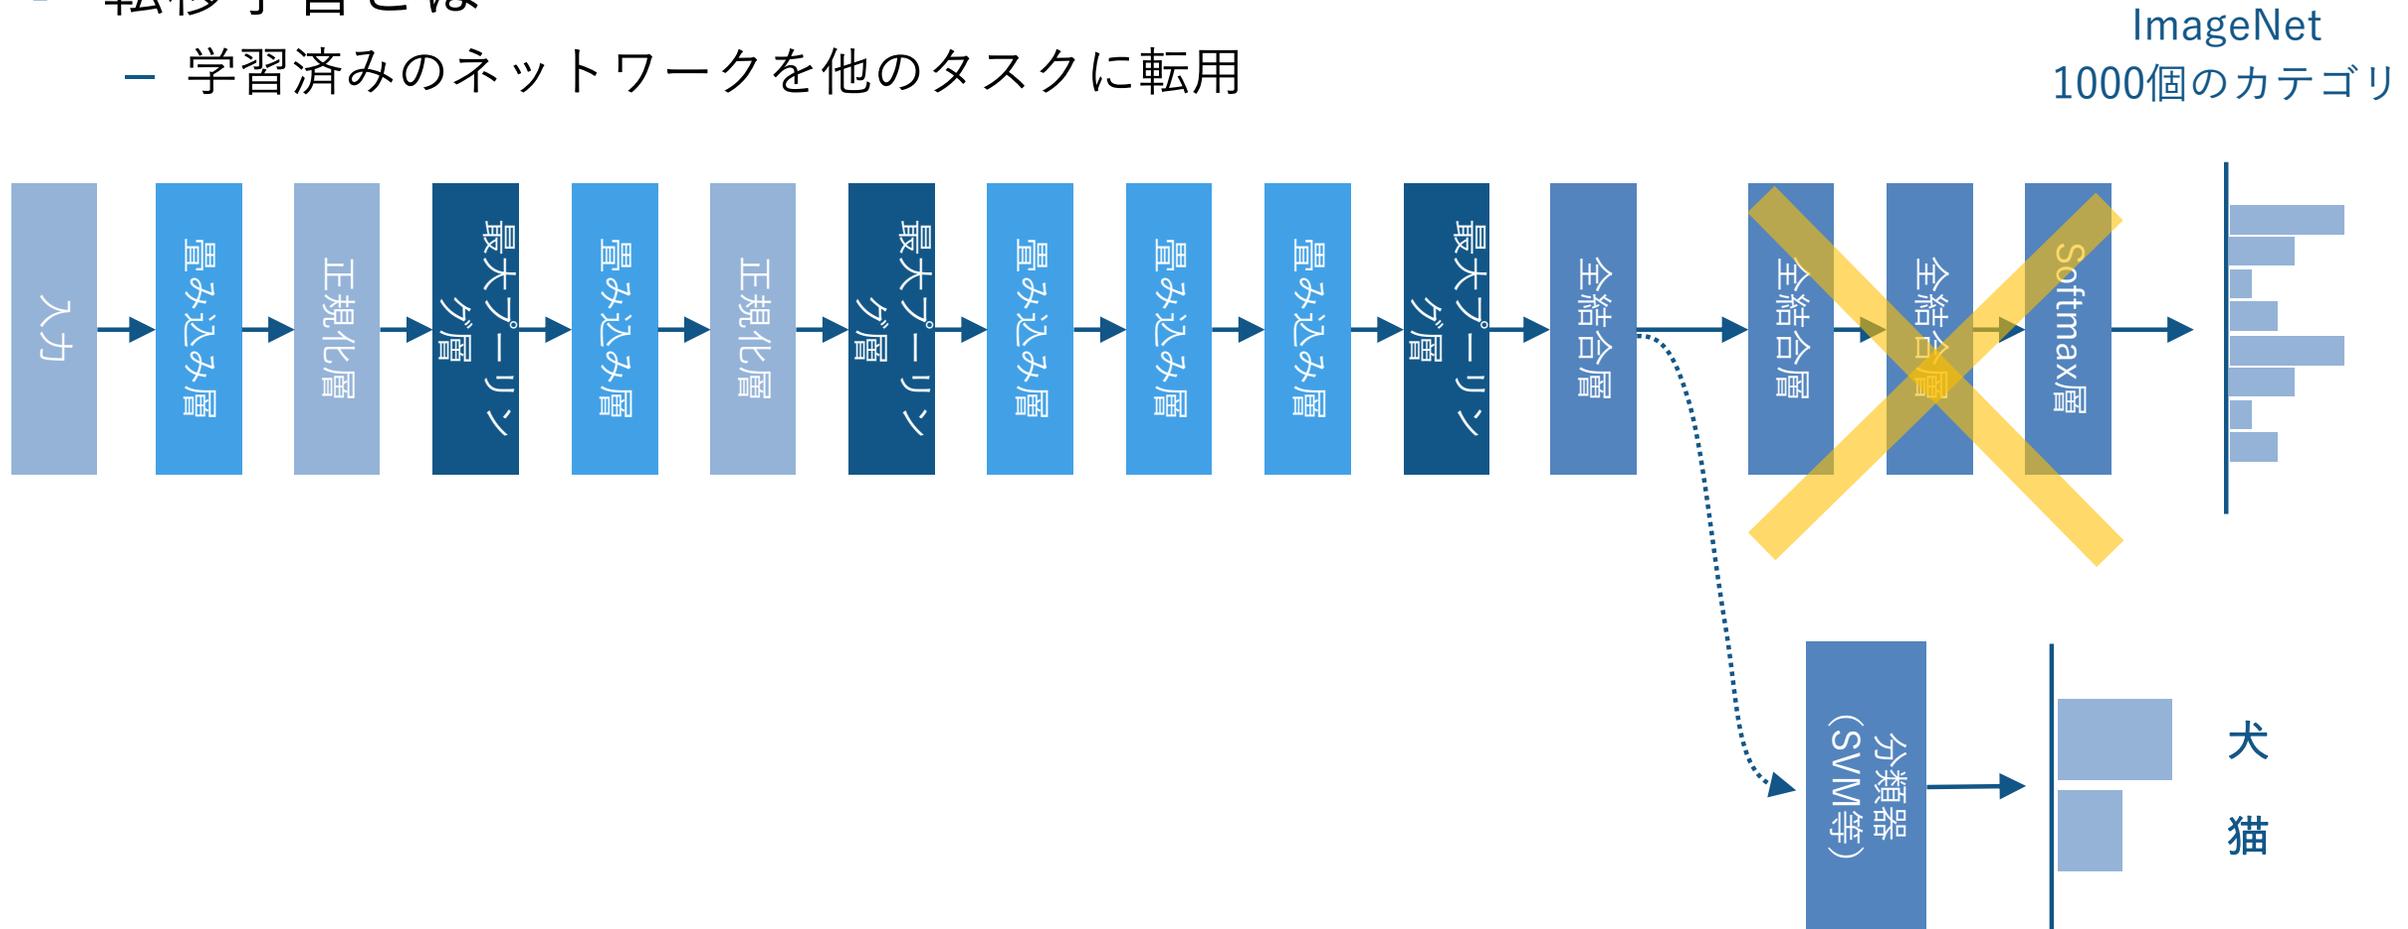
# 畳み込みニューラルネットワーク

- AlexNet : ILSVRC2012 で優勝した CNN の構成



# 転移学習

- 転移学習とは
  - 学習済みのネットワークを他のタスクに転用



# 転移学習の応用例

- 見分けにくい画像の判別



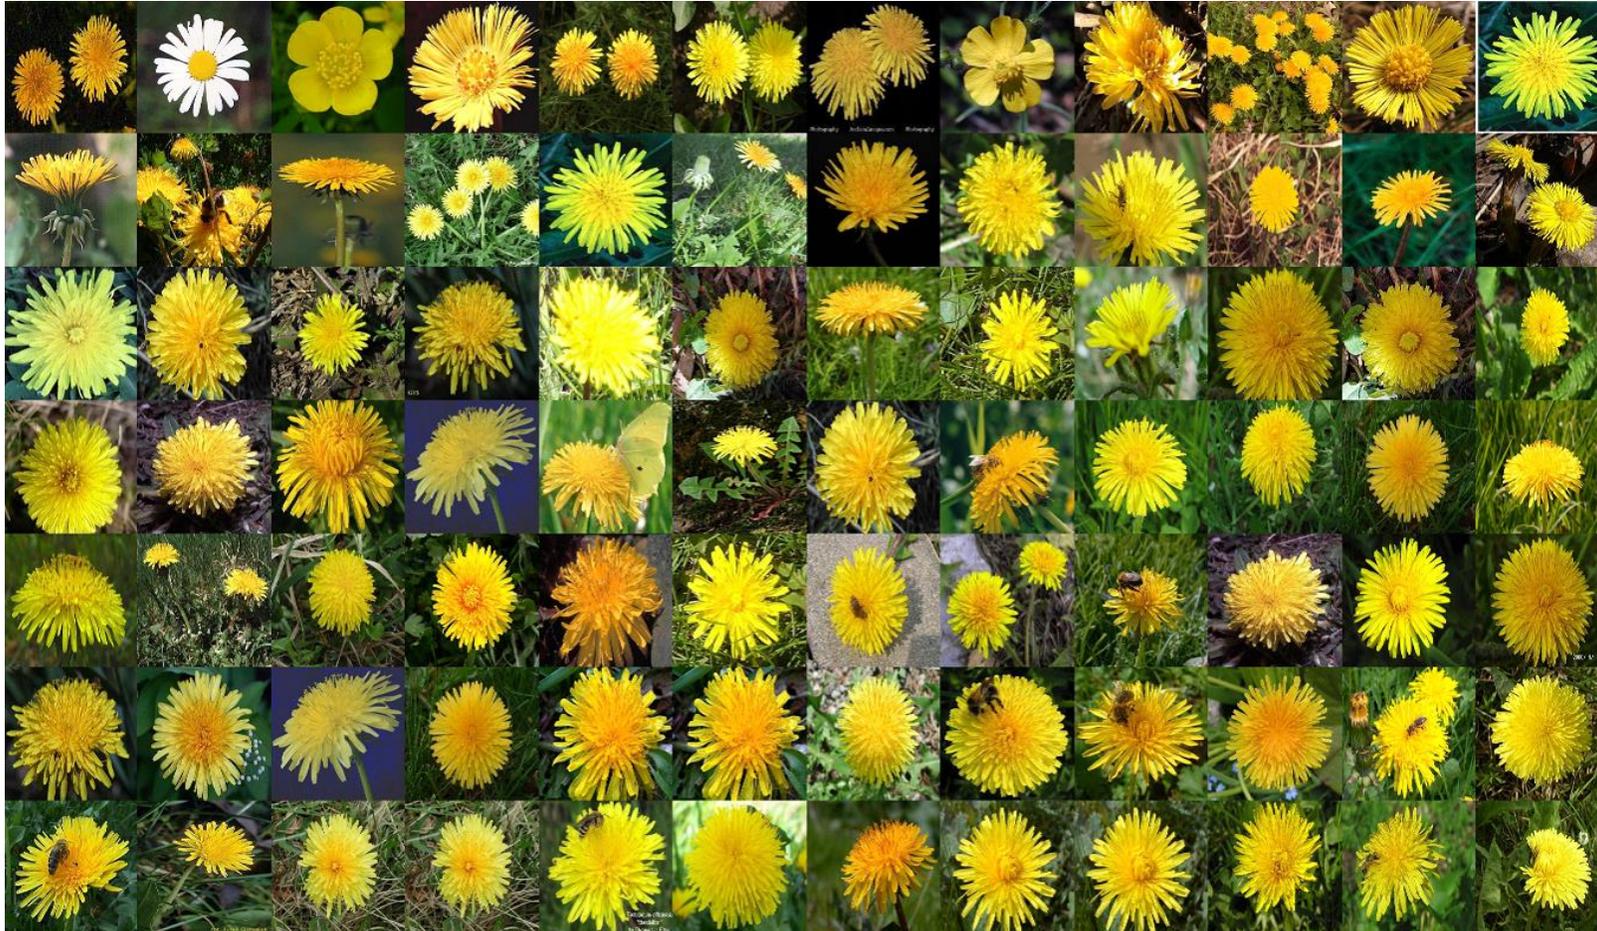
タンポポ  
(Dandelion)



フキタンポポ  
(Colts' Foot)

# 例5: 転移学習で抽出した特徴を使った異常検出

異常度：高

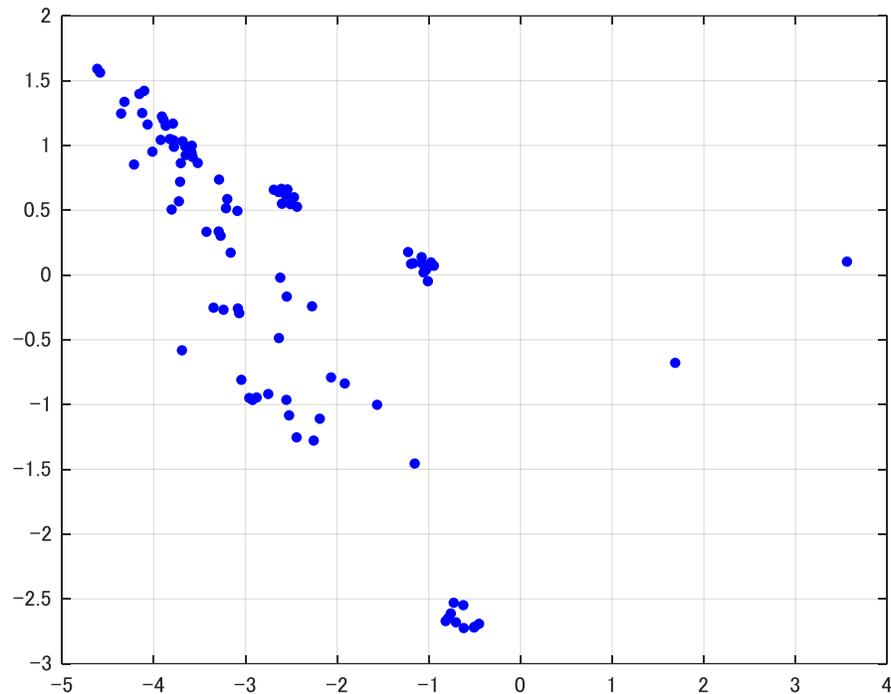


異常度：低

# 異常検出の手法

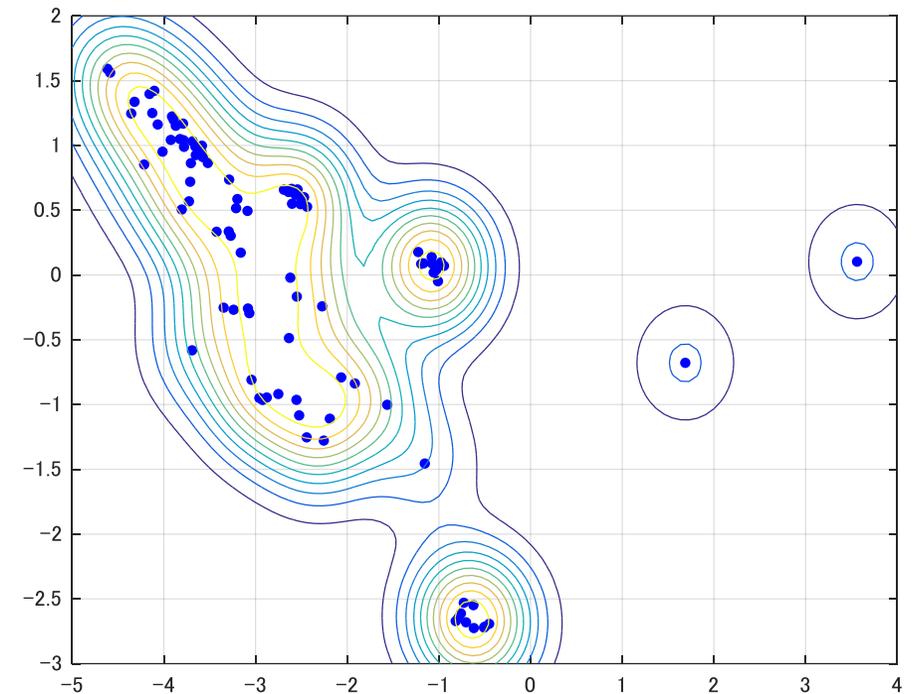
## 1-Class SVM

- データセット内に異常がどれくらい含まれているか既知の場合に有効



異常データを含むデータの例

1-Class SVM



スコアの値が高い方が正常度が高い

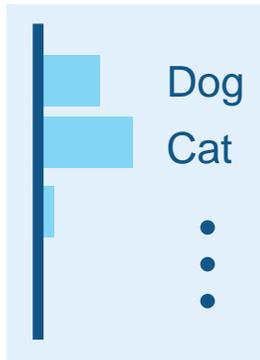
# Outline

- 機械学習の基礎
  - 教師あり学習と教師なし学習
  - 教師あり学習 – 回帰と分類
- Case1: 特徴が明確な場合の数値の分類
  - ニューラルネットワーク以外の機械学習
- Case2: 特徴が不明瞭な場合の信号分類
  - ニューラルネットワーク
- Case3: 特徴が不明瞭な場合の信号データの異常検出
  - オートエンコーダ
- Case4: **画像データの分類と異常検出**
  - CNN と 転移学習
  - 他のアルゴリズム

# 画像分野におけるディープラーニングアルゴリズムの使い分け

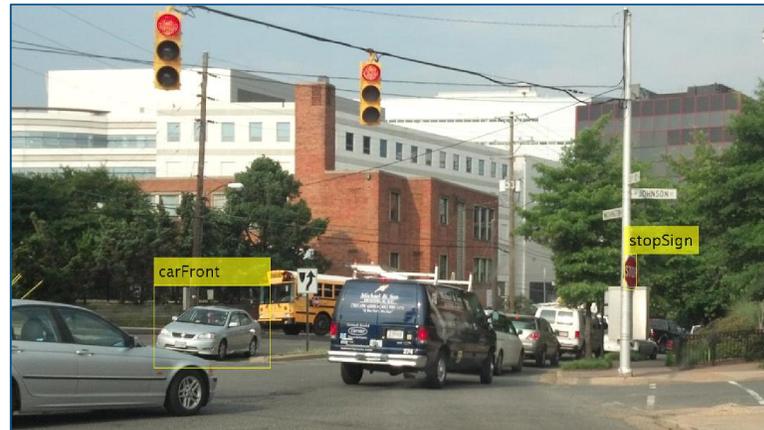
物体認識 (画像全体)

CNN



複数物体の検出と認識

R-CNN  
Fast R-CNN  
Faster R-CNN

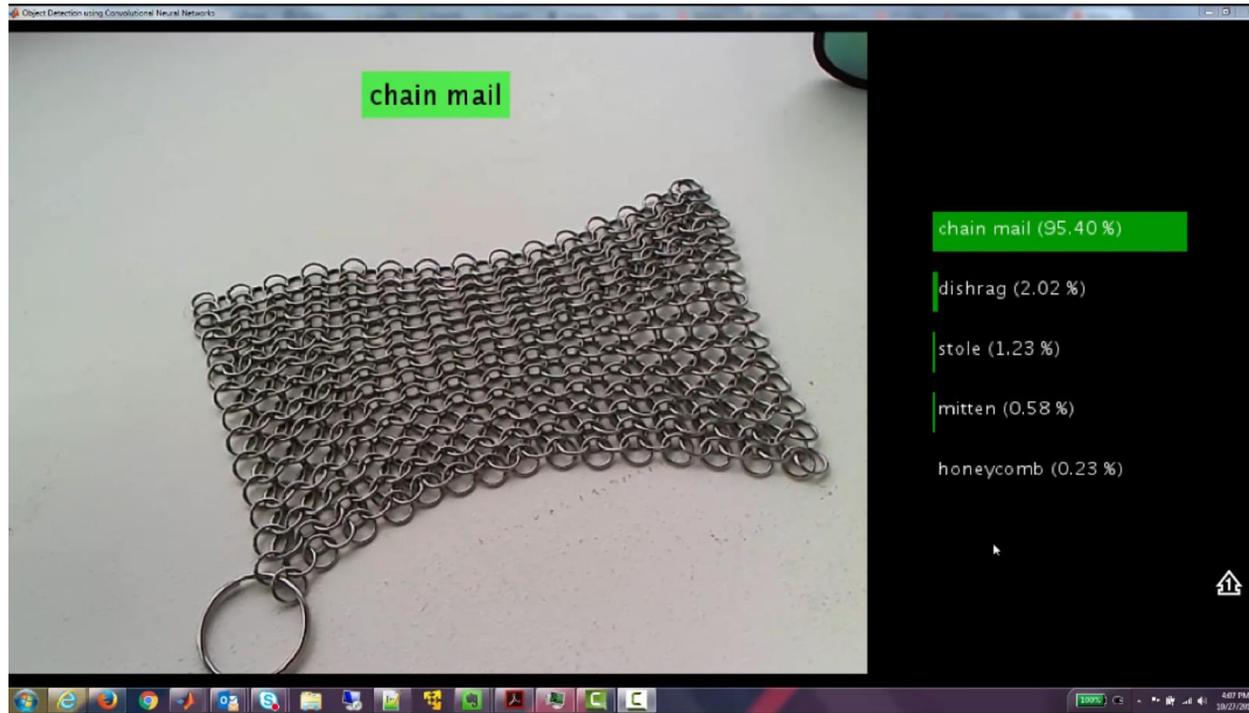


物体認識 (ピクセル単位)

SegNet  
FCN

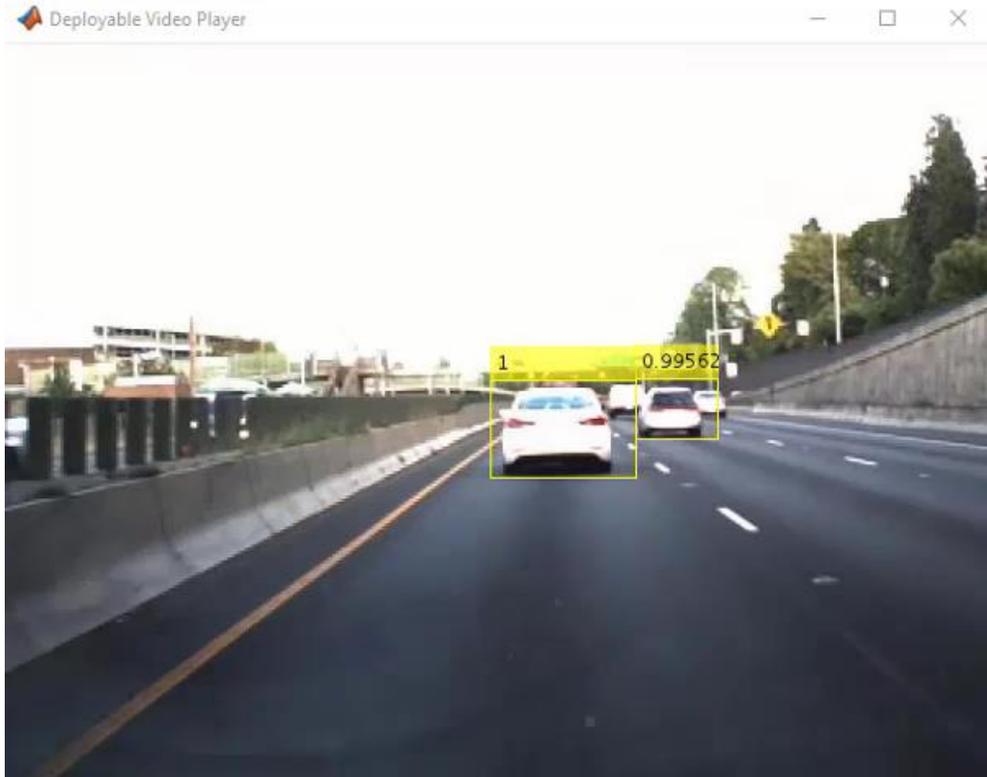


# 例1: CNN による物体判別



<b>Training (GPU)</b>	Millions of images from 1000 different categories
<b>Prediction</b>	Real-time object recognition using a webcam connected to a laptop

## 例2: R-CNN/Semantic Segmentation による複数物体の局所的判別

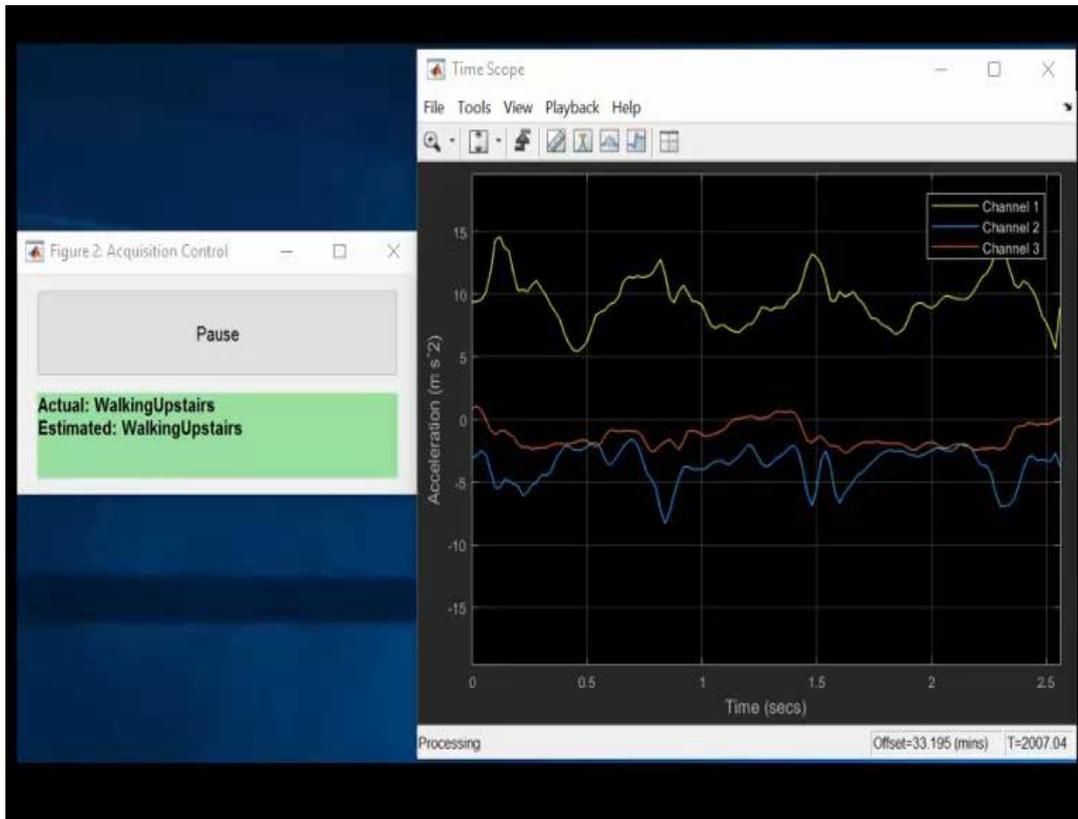


**Regions with Convolutional Neural Network Features (R-CNN)**

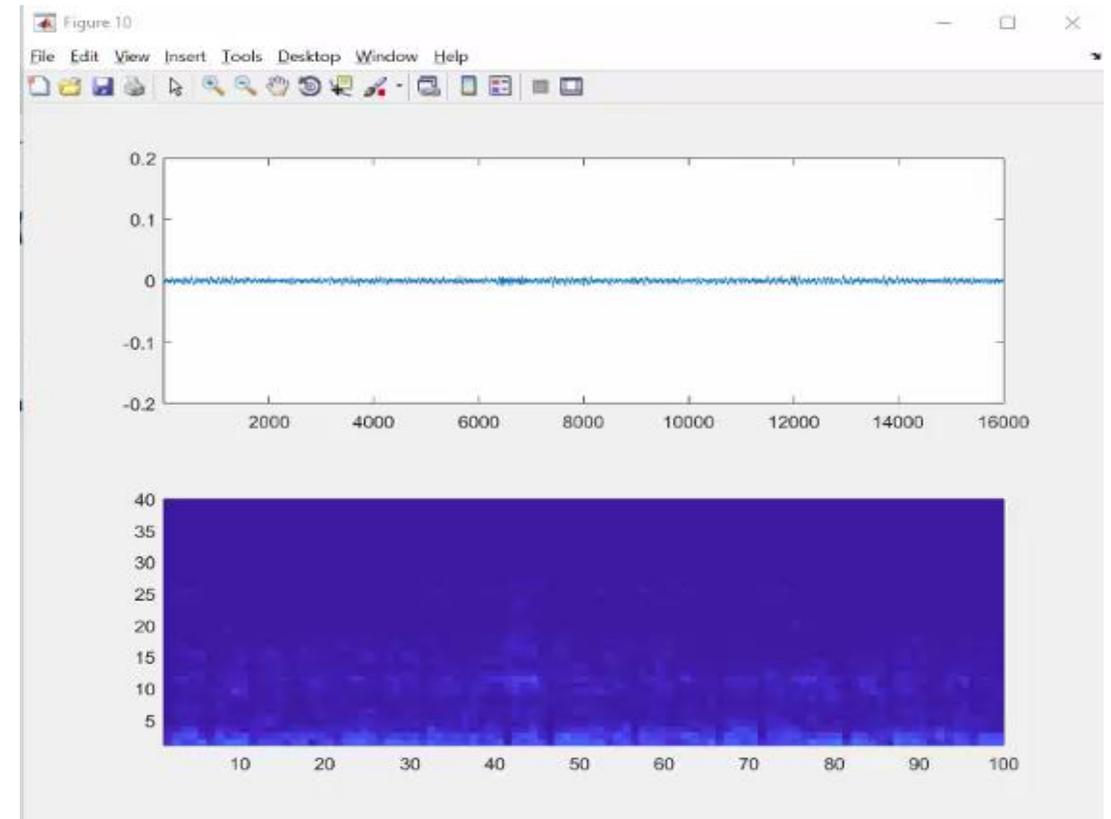


**Semantic Segmentation using SegNet**

## 例3: LSTM や CNN を使用した信号データの分類/判別



Signal Classification using LSTMs



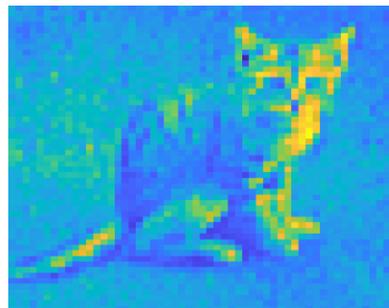
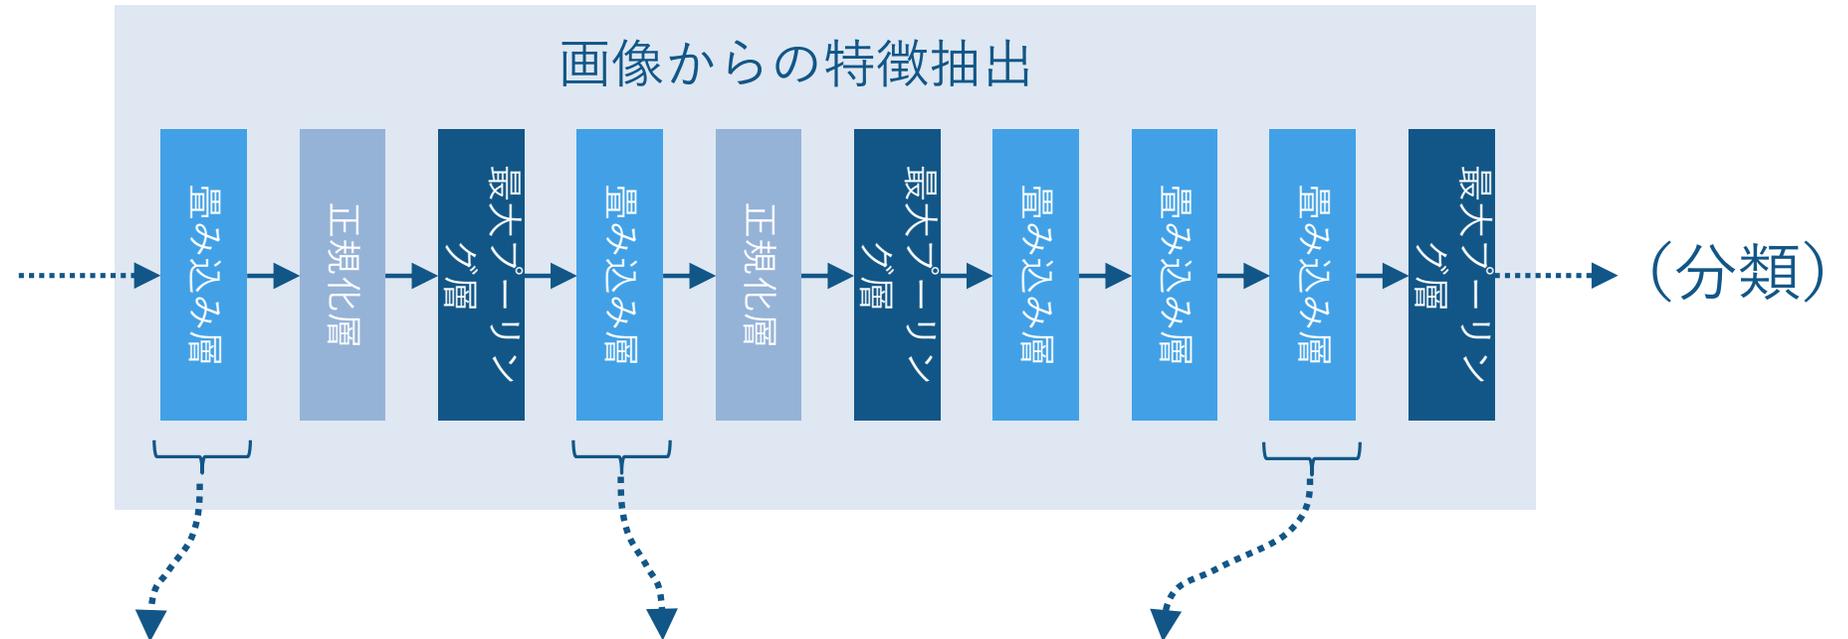
Speech Recognition using CNNs

# Feature Map とは？

畳み込みニューラルネットワークの計算過程で出てくる畳み込みの出力

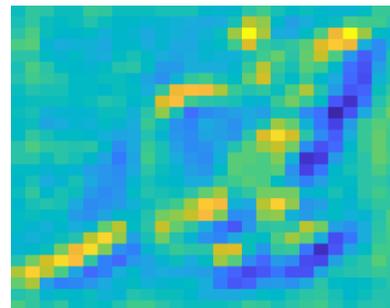


227 x 227

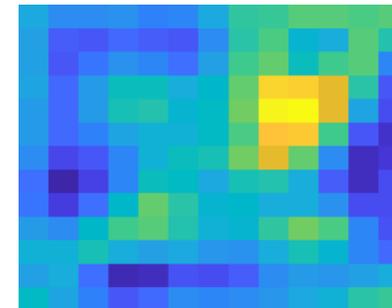


55 x 55

ピクセル単位の情報からエッジなどの空間情報を取り出している



27 x 27

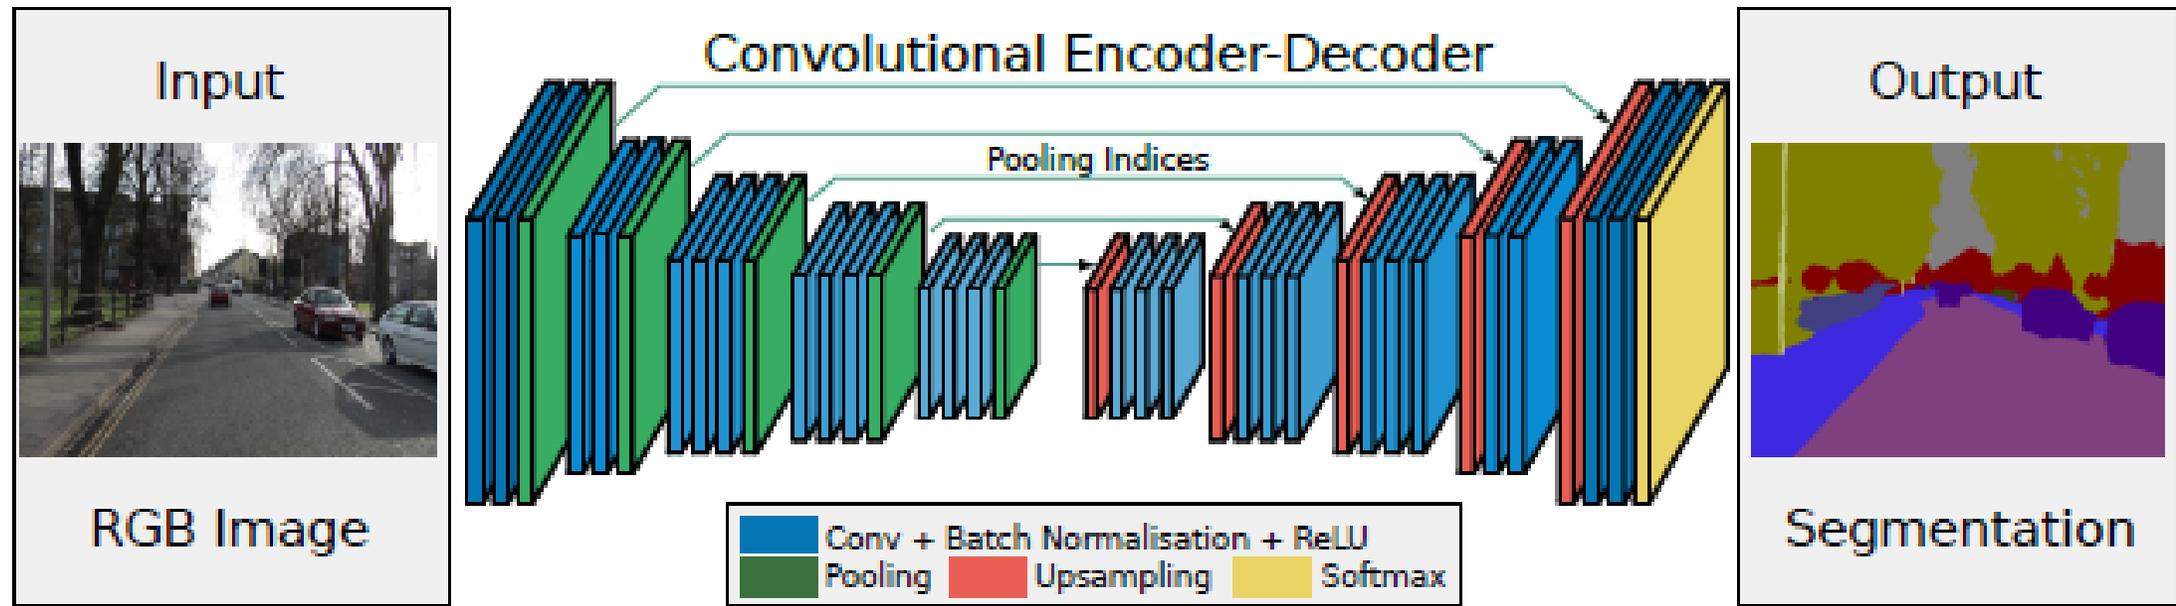


13 x 13

プーリングの反復により位置に関する情報が粗くなってしまう

# SegNet (Semantic Segmentation)

Max Pooling時のIndexを転送して位置に関する情報を補充している

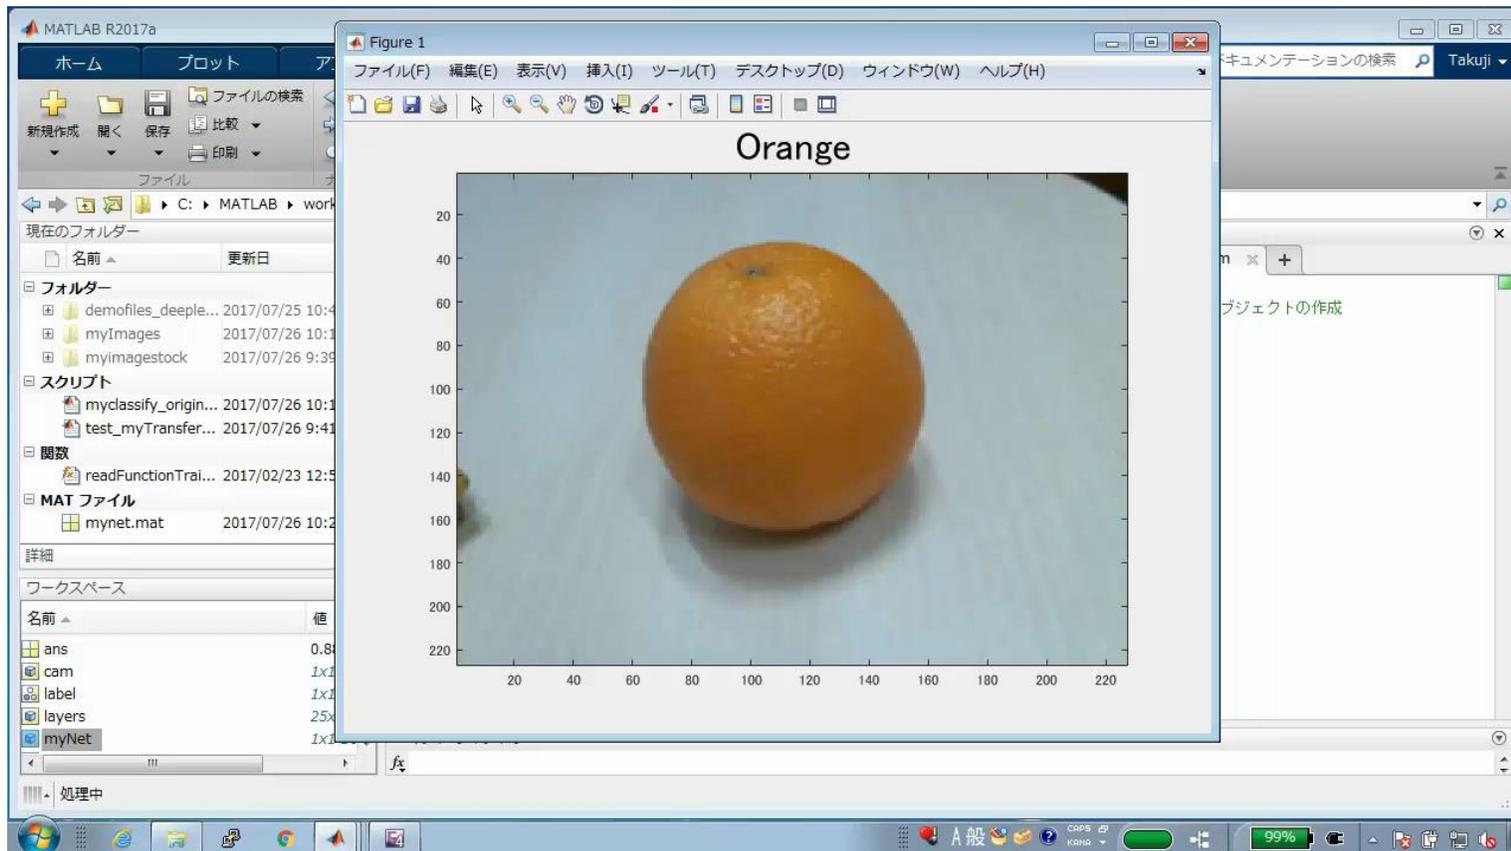


Badrinarayanan, V., A. Kendall, and R. Cipolla. "Segnet: A deep convolutional encoder-decoder architecture for image segmentation." arXiv. Preprint arXiv: 1511.0051, 2015.

# 学習リソース

# ディープラーニングによる物体認識

- ディープラーニング：10行でできる転移学習 ～画像分類タスクに挑戦～



学習した画像の種類:

- オレンジ
- みかん
- グレープフルーツ(ルビー)
- グレープフルーツ(ホワイト)
- レモン

学習画像数：各 20 枚

**Requirements:**

- 要件を満たすPC&MATLAB環境
- 学習済み AlexNet
- 判別したい画像ファイル  
と10行のコーディングで始められます

# 製造現場で使える画像による異常検知

## ～キズあり「ナット」の発見～

The screenshot shows the MATLAB R2017a environment. The main window displays a folder named 'anomaly' containing four images of nuts. The second image (labeled 98) is highlighted, indicating it is an anomaly. The MATLAB editor shows the following code:

```
1 - categ2 = {'te
2 - imds2 = image
3 - imds2.ReadFcn
4 - tic
5 - testFeatures
6
7 - testLabels =
8 - [~, score] =
9 - [score_sorted
10 - idxfail = idx
11 - idx(1:25) %
12 - toc
13 %% 異常が高し
```

The command window shows the following output:

```
Files: {
...
}
Labels: [anomaly; anomaly; anomaly ... and 97 more categorical]
ReadSize: 1
ReadFcn: @readDatastoreImage
```

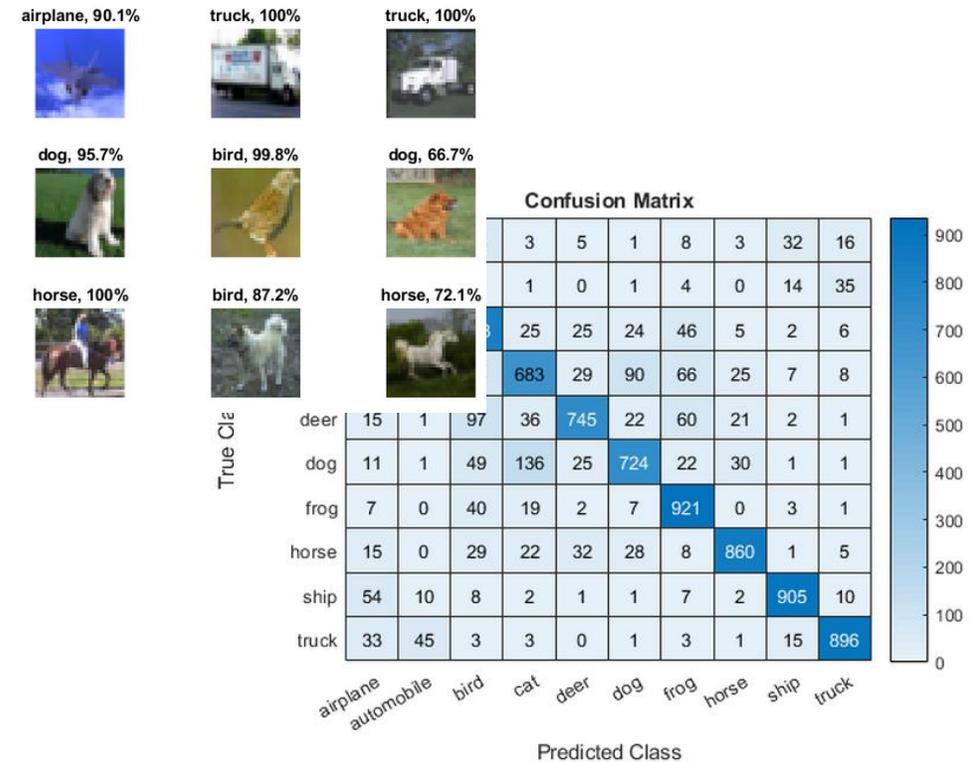
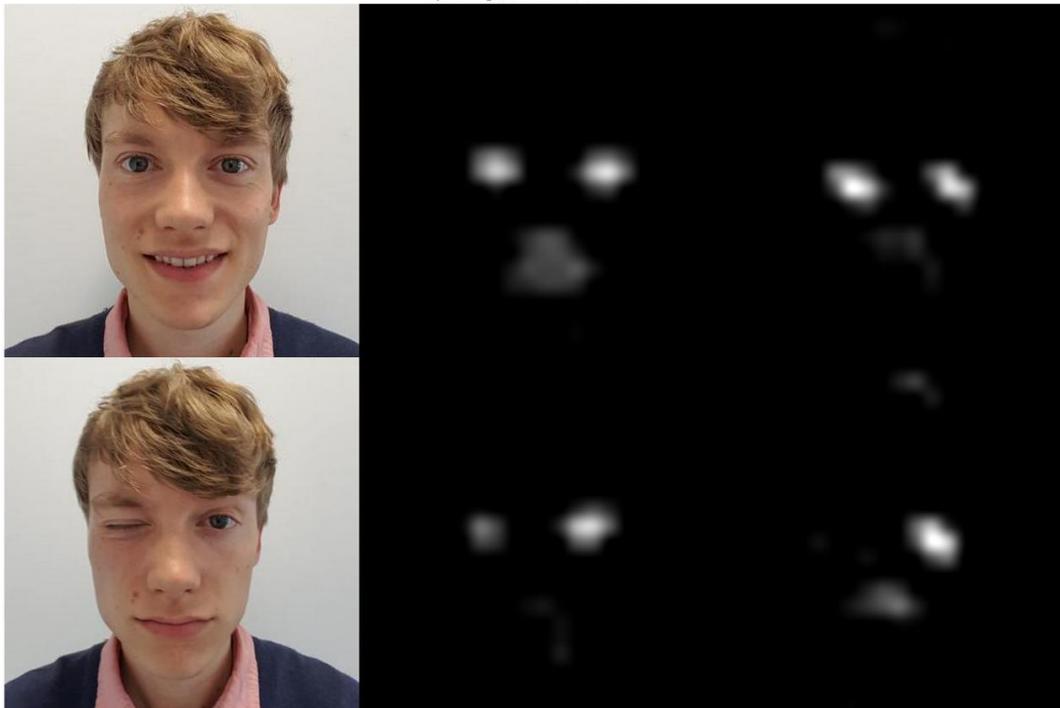
The workspace shows the following variables:

名前	値
ans	25x1 double
categ	1x1 cell
categ2	1x1 cell
convnet	1x1 SeriesNetwork
d	1x1 ClassificationS...

<https://www.youtube.com/watch?v=brNuygyOmBQ>

# 精度向上を手助けするサンプルプログラム

たたみ込みニューラル ネットワークの活性化の可視化 ベイズ最適化を用いたディープラーニング



<https://www.mathworks.com/help/releases/R2017b/nnet/examples/visualize-activations-of-a-convolutional-neural-network.html>

<https://www.mathworks.com/help/releases/R2017b/nnet/examples/deep-learning-using-bayesian-optimization.html>

# 実践的な学習を自分のペースで

データを読み解くための機械学習  
 - MATLABでデータ解析の問題に立ち向かう

<https://jp.mathworks.com/videos/machine-learning-for-understanding-data-tackling-data-analytics-issues-with-matlab-102659.html>

**ガウス過程回帰**

- ガウス過程回帰 (Gaussian Processes, Kriging)
  - ノンパラメトリックな確率モデル
  - 訓練データに近ければ分散が小、離れると分散大のガウス分布から確率的に生成されていると仮定 (近傍とのなめらかな遷移を仮定)
- 利点
  - サンプル数が少ない場合にも高い予測精度
  - 途中でサンプルの傾向が変わった場合に対応可能
- 欠点
  - 高次元のデータでは予測精度が高くない

**ハイパーパラメータの調節**

ハイパーパラメータのグリッドサーチ

パラメータ 1

**条件**

- 低次元データ
- 目的関数の評価に時間がかかる
- 低精度
- 大域的な解を求めたい
- ハイパーパラメータの決定

## MATLAB Academy

<https://matlabacademy.mathworks.com/jp>

タスク 1  
タスク 2

Info: 関数 `imresize` を使用して、イメージのサイズを変更できます。

```
imgresz = imresize(img,[numrows numcols]);
```

これは、`img` のサイズを `numrows` x `numcols` に変更します。つまり、`imgresz` の幅は `numcols` ピクセルで、高さは `numrows` ピクセルになります。

関数 `imresize` を使用して、変数 `img` に格納されたイメージのサイズを `227` x `227` に変更してください。結果は、元の変数 `img` に格納してください。

タスクへ移動

タスク 3  
追加の練習

タスク 2: 画像サイズの変更

```
img = imresize(img, [227 227]);
```

タスク 3: グレースケールから RGB に変更

```
img = repmat(img,[1 1 3]);
```

結果の表示

```
imadjust でコントラスト調整
imshow(imadjust(img,stretchlim(img)))
```

画像情報の追加

```
[m,n,p] = size(img);
title(['img is ',num2str(m),' x ',num2str(n),' x ',num2str(p)])
```

img is 227 x 227 x 3

WEBブラウザ上で  
 MATLABディープラーニングの操作体験